

# PENGENALAN EKSPRESI RAUT WAJAH BERBASIS JARINGAN SARAF TIRUAN BACKPROPAGATION DENGAN METODE *PRINCIPAL COMPONENT ANALYSIS*

## *Facial Emotion Recognition Base Artificial Neural Network Backpropagation With Principal Component Analysis Method*

Harizahayu\*

Prodi Manajemen Informatika Jurusan Teknik Komputer dan Informatika Politeknik Negeri Medan  
Jl. Almamater No.1 Kampus USU, Medan, 20155, Indonesia

Corresponding author e-mail: \* [harizahayu@polmed.ac.id](mailto:harizahayu@polmed.ac.id)

### Abstrak

Perkembangan jaringan saraf tiruan berkaitan dengan analisis statistik dan biometrik yang merupakan salah satu aplikasi yang dapat diselesaikan dengan model-model jaringan saraf tiruan. Pengenalan pola wajah merupakan bagian penting untuk mengidentifikasi seseorang. Wajah dapat dibagi menjadi beberapa area seperti hidung, mata, dan mulut. Pengenalan pola wajah merupakan suatu bidang penelitian yang dapat diterapkan ke dalam metode *principal component analysis* (PCA). Proses pelatihan yang dilakukan oleh perhitungan *eigenface* ini menggunakan PCA dan hasil penelitian ini memperlihatkan bahwa pengenalan pola wajah berdasarkan persentase memorisasi dan generalisasi untuk penggunaan metode tanpa PCA lebih baik dibandingkan dengan pengenalan pola wajah menggunakan PCA. Pengenalan pola tanpa menggunakan metode PCA tingkat memorisasi dan generalisasi mencapai 100% pada iterasi yang ke-40 dan kesalahan 0,0099 dengan laju pembelajaran dan momentum bernilai 0,8 sedangkan pengenalan pola wajah menggunakan metode PCA tingkat memorisasi dan generalisasi mencapai 100% pada iterasi ke-1000 dan kesalahan 0,00103 dengan laju pembelajaran dan momentum 0,9.

**Kata Kunci** : Jaringan saraf tiruan, *Principal Component Analysis*, Pengenalan pola wajah, *Eigen value*, *Eigen vektor*

### Abstract

The development of artificial neural networks is related to statistical and biometric analysis which is one of the applications that can require artificial neural network models. Recognition of facial patterns is an important part of identifying a person. The face can be divided into areas such as the nose, eyes and mouth. Face pattern recognition is a research area that can be applied to the *principal component analysis* (PCA) method. The training process carried out by the *eigenface* calculation uses PCA and the results of this study show that facial pattern recognition based on the proportion of memorization and generalization for the use of the method without PCA is better than facial pattern recognition using PCA. Pattern recognition without using the PCA method, the level of memorization and generalization reaches 100% at the 40th iteration and 0.0099 error with a learning rate and momentum of 0.8, while facial pattern recognition using the PCA method, the memorization and generalization level reaches 100% in the iteration. to -1000 and error 0.00103 with learning rate and momentum 0.9.

**Keywords**: Artificial Neural Network, *Principal component analysis*, Face recogniton, *Eigen value*, *Eigen Vector*

### Article info:

Received: 21<sup>st</sup> September 2020

Accepted: 26<sup>th</sup> February 2021

### How to cite this article:

Harizahayu, "PENGENALAN EKSPRESI RAUT WAJAH BERBASIS JARINGAN SARAF TIRUAN BACKPROPAGATION DENGAN METODE PRINCIPAL COMPONENT ANALYSIS", *BAREKENG: J. Il. Mat. & Ter.*, vol. 15, no. 1, pp. 037-046, Mar. 2021.



This work is licensed under a [Creative Commons Attribution-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-sa/4.0/).  
Copyright © 2021 Harizahayu

## 1. PENDAHULUAN

Penelitian terhadap pengenalan pola wajah manusia adalah salah satu bidang penelitian penting yang aplikasinya dapat diterapkan dengan banyak metode yang memiliki kelebihan dan kekurangan tertentu. Hal ini disebabkan karena wajah manusia merepresentasikan sesuatu yang kompleks [1][2][3][4], sehingga untuk mengembangkan komputasi yang ideal pada pengenalan wajah adalah sesuatu hal yang sulit. Pengenalan Pola wajah dengan *background*, pencahayaan, ekspresi, kondisi atau rintangan yang berbeda sehingga membuat perbedaan pendekatan untuk pengenalan pola wajah menjadi suatu eksperimen yang sangat menarik untuk diteliti [3]. Adapun perangkat lunak yang dipilih berasal dari MATLAB *Image Processing Toolbox* (IPT) [4] [5], yang juga menempati posisi terdepan dalam pendidikan dan industri menyediakan sebuah integrasi tanpa batas dari konsep teori yang mapan dan implementasinya menggunakan alat perangkat lunak terancang [1][6].

Perkembangan jaringan saraf tiruan yang berkaitan dengan analisis statistik dan biometrik merupakan salah satu aplikasi yang dapat diselesaikan dengan model-model jaringan saraf tiruan. Sebuah ciri biologi yang dapat memberikan informasi untuk mengidentifikasi masing-masing individu. Dalam teknologi informasi, biometrik biasanya merujuk kepada teknologi yang mengukur dan menganalisis karakteristik tubuh manusia seperti sidik jari, retina, mata, pola suara, dan pola wajah yang terutama digunakan untuk proses otentifikasi [7][8]. Jaringan saraf tiruan mampu mengenali sesuatu dengan berbasis masa lalu. Hal ini berarti data masa lalu akan dipelajari sehingga mampu memberi keputusan terhadap data baru [9][10]. Objek penelitiannya berupa jaringan saraf tiruan bertujuan untuk memahami dan mengembangkan sistem pengenalan rumus dan simbol matematika. Adapun ketentuan prinsip kerja jaringan saraf, adalah fungsi jaringan saraf otak manusia [3][11]. Penjelasan representasi matematis dari pulsa yang melewati koneksi sinaptik *neuron* dan pemrosesannya untuk tindakan lebih lanjut. Hal ini membuat metode ini sangat berguna di *era big data* dan pengobatan yang dipersonalisasi *latypora* [11].

Banyak metode yang dapat digunakan untuk menganalisis pengenalan pola wajah, tetapi dalam penelitian ini hanya menggunakan metode *principal component analysis* (PCA) yang berbasis jaringan saraf tiruan (JST) membuat kinerja sistem lebih cepat dan akurat tanpa harus menghilangkan informasi yang penting pada data [3][9][10][12]. PCA yaitu suatu metode yang mampu mereduksi dimensi dari suatu objek, sehingga ukuran dari objek yang akan lebih ringkas dan mampu mengambil karakteristik yang penting dari suatu objek yang akan diolah. Jika dimensi dari objek lebih kecil dan informasi yang lebih padat, maka objek tersebut akan lebih spesifik dibanding objek yang diolah sebelumnya [8][13]. Pengenalan pola wajah merupakan suatu pengenalan pola (*pattern recognition*) yang khusus untuk kasus wajah [14]. Beberapa pendekatan untuk pengenalan objek dan grafika komputer didasarkan secara langsung pada citra-citra tanpa penggunaan model tiga dimensi [11]. *Principal component analysis* merupakan suatu metode yang mengekstraksi ciri atau kompresi data yang mampu mengidentifikasi ciri tertentu yang merupakan karakteristik dari suatu citra (dalam penelitian ini adalah wajah) [13][15].

Algoritme *backpropagation* merupakan suatu algoritme yang sangat baik dalam menangani masalah pengenalan pola-pola yang kompleks. Istilah *backpropagation* atau penyiaran kembali diambil dari cara kerja jaringan ini, yaitu *gradient error unit output* [2][6][16]. Hal ini karena nilai target untuk unit-unit tersembunyi tidak diberikan. Beberapa tahapan *backpropagation* yaitu dengan inisialisasi bobot, aktivasi, menghitung bobot input dan bias output dan perubahan bobot dan bias. Tahapan tersebut akan diperoleh *output* yang ingin dicapai dengan pendekatan *error* terkecil [5]. Pada jaringan saraf *backpropagation* ada beberapa faktor yang dapat diteliti untuk melakukan hal tersebut dengan menetapkan nilai *learning rate* ( $\alpha$ ) dan momentum ( $\beta$ ). Penentuan dan penyesuaian bobot laju pembelajaran (*learning rate*) yang cepat menentukan tercapainya tingkat konvergensi ke arah *error* yang diinginkan. Semakin besar nilai *learning rate* akan berimplikasi semakin besarnya pembelajaran [4].

Berdasarkan penelitian sebelumnya maka pada penelitian ini penulis memilih metode *principal component analysis* untuk mendeteksi pola wajah tanpa harus menghilangkan informasi yang ada pada data dan membandingkannya dengan pendeteksian pola wajah tanpa menggunakan metode PCA, sehingga dapat dijabarkan sebagai berikut: “Bagaimana kinerja jaringan saraf tiruan *backpropagation* untuk pengenalan pola wajah dengan metode *principal component analysis* (PCA)”. Sedangkan tujuan penelitian ini yang pertama adalah peneliti memahami dan mengamati konsep jaringan saraf tiruan dan proses algoritma *backpropagation* dengan menetapkan *learning rate* ( $\alpha$ ) dan *momentum* ( $\beta$ ) dan yang kedua peneliti membandingkan penggunaan metode *principal component analysis* dan tanpa penggunaan metode untuk data masukan pengenalan pola wajah pada jaringan saraf tiruan *backpropagation*.

## 2. METODE PENELITIAN

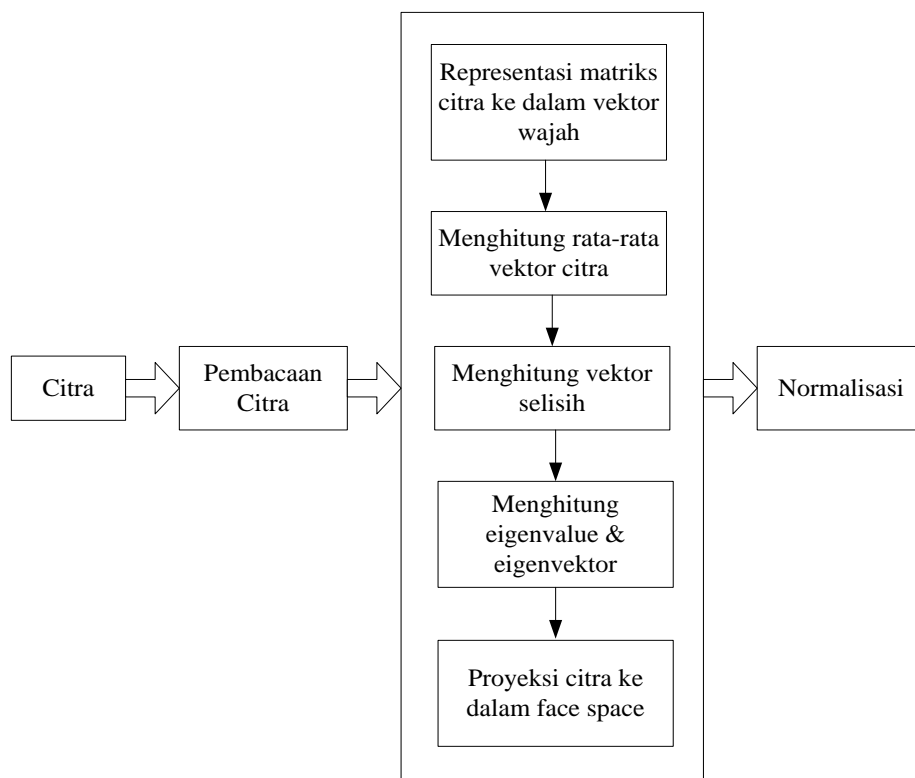
Pada penelitian ini, digunakan 30 citra wajah yang terdiri dari 5 (lima) orang. Setiap wajah orang diambil sampel sebanyak 6 (enam) citra dengan ekspresi yang berbeda-beda, dimana 4 citra digunakan sebagai tahap pelatihan (*simple learning*) dan 2 citra digunakan sebagai tahap pengujian (*sample detection*).

### 2.1 Pengambilan *Image* Wajah

Pengambilan *image* (gambar) wajah dilakukan dengan menggunakan kamera digital dengan format JPEG, mode RGB, dan beresolusi  $640 \times 640$  terhadap 5 (lima) orang berdasarkan enam konfigurasi dasar wajah manusia secara psikologis, yaitu : kaget, marah, netral, tertawa, sedih, senyum, dan tertawa. Untuk memenuhi syarat penelitian ini, dilakukan perubahan terhadap karakteristik *image* wajah tersebut. Dengan menggunakan perangkat lunak *Adobe Photoshop* karakteristik *image* wajah tersebut diubah menjadi PCX, *gray mode* level 8 bit dan beresolusi  $64 \times 64$ . Pengambilan ciri wajah dilakukan dengan cara mengkroping citra beresolusi  $30 \times 30$  dengan pusat kroping adalah koordinat hidung. Bagian wajah yang dikroping meliputi mata, hidung, dan mulut.

### 2.2 Representasi *Image* dengan *Principal Component Analysis*

*Principal component analysis* (PCA) adalah dengan memproyeksi *image* ke dalam ruang eigennya atau ruang wajah. Cara mendapatkannya adalah dengan mencari *eigenvector* yang dimiliki setiap *image* dengan memproyeksikan ke dalam ruang wajah [17]. Sasaran PCA dapat menangkap variasi total di dalam kumpulan wajah yang dilatihnya. Adapun langkah-langkah yang dilakukan PCA dalam proses pengenalan wajah adalah sebagai berikut:



Metode PCA

**Gambar 1. Tahapan Pengolahan Citra**

Pembacaan citra merupakan proses perubahan *image* dari keadaan kontinu ke keadaan diskrit agar dalam ekstraksi dapat dimengerti oleh komputer. Hasil perubahan wajah terhadap sebuah citra wajah yang digunakan pada penelitian ini adalah matriks berukuran  $30 \times 30$  yang berisi nilai-nilai diskrit dari setiap citra

wajah. Peneliti menggunakan data tersebut dengan melakukan pelabelan terhadap citra wajah dengan cara sebagai berikut:

**Tabel 1. Pelabelan Data Diskrit Citra Wajah**

Objek	Ekspresi Wajah					
	Kaget	Marah	Netral	Sedih	Senyum	Tertawa
Orang-1	Foto-1A	Foto-2A	Foto-3A	Foto-4A	Foto-5A	Foto-6A
Orang-2	Foto-7A	Foto-8A	Foto-9A	Foto-10A	Foto-11A	Foto-12A
Orang-3	Foto-13A	Foto-14A	Foto-15A	Foto-16A	Foto-17A	Foto-18A
Orang-4	Foto-19A	Foto-20A	Foto-21A	Foto-22A	Foto-23A	Foto-24A
Orang-5	Foto-25A	Foto-26A	Foto-27A	Foto-28A	Foto-29A	Foto-30A

Setelah semua citra dibaca oleh *software readImage* akan diperoleh *file* dari tiap citra yang berisi vektor-vektor yang mempunyai ukuran  $30 \times 30$ . Kemudian semua *file* dari tiap citra dibaca dengan Matlab 7.1, yang menghasilkan vektor yang masing-masing berdimensi  $N^2 \times 1$  ( $N$  = ukuran dari masing-masing resolusi citra). Vektor-vektor yang diperoleh digabungkan menjadi sebuah matriks berukuran  $N^2 \times 30$  untuk masing-masing resolusi citra yang disimpan ke dalam *file* "data1".

Tahap kedua adalah Perhitungan *noise* pada vektor tau merupakan data training dan membuat vektor baru (*phi*) yang merupakan vektor tau yang bebas dari noise dengan menghitung nilai pembeda (*eigen value*) antara vektor satu dengan vektor yang lain membuat *eigen vector* ( $V_{eigen}$ ) yang diurutkan (*GoodV*) berdasarkan *eigen value* terbesar dan membentuk *principal component analysis* (*construct*) yang telah tereduksi ukurannya (*extract*).

Dalam aljabar linier [3][18], Vektor eigen dari operator linier adalah vektor bukan-nol yang, bila dioperasikan untuk menghasilkan kelipatan skalar darinya. Skalar inilah yang kemudian disebut dengan nilai *eigen* ( $\lambda$ ) yang dikaitkan dengan vektor *eigen*. Vektor *eigen* adalah vektor yang diskalakan dengan transformasi linier. Ini adalah properti matriks, ketika matriks bekerja di atasnya, hanya besaran vektor yang berubah bukan arahnya.

$$AX = \lambda X \quad , \quad A \text{ adalah sebuah fungsi vektor} \quad (1)$$

$$(A - \lambda I)X = 0 \quad , \quad I \text{ adalah matriks identitas} \quad (2)$$

Persamaan (2) adalah sistem persamaan homogen yang membentuk fundamental aljabar linier. Diketahui bahwa solusi non trivial ada jika dan hanya jika  $Det(A - \lambda I) = 0$ , di mana *Det* menunjukkan determinan. Ketika persamaan  $Det(A - \lambda I) = 0$  dievaluasi menjadi apolinomial yang berderajat  $n$  maka persamaan disebut polinomial karakteristik  $A$ . Jika  $A$  adalah  $N$  untuk  $N$  maka ada  $n$  solusi atau  $n$  akar polinomial karakteristik [19]. Jadi ada  $n$  nilai *eigen* dari  $A$  yang memenuhi persamaan tersebut.

$$AX_i = \lambda_i X_i, \quad i = 1, 2, \dots, n \quad (3)$$

Jika semua nilai *eigen* berbeda, ada  $n$  vektor eigen yang bersifat *independen linier* terkait, arahnya unik dan menjangkau  $n$  dimensi ruang *euclidean* [3].

Himpunan data training dari  $m$  images yang berukuran  $N \times N$  yang diwakilkan dengan vektor berukuran  $N^2$ . Tiap-tiap wajah direpresentasikan oleh  $\Gamma_1, \Gamma_2, \Gamma_3, \dots, \Gamma_m$ . Fitur Vektor dari sebuah face disimpan dalam matriks  $N \times N$ . Sekarang, vektor dua dimensi ini diubah menjadi vektor satu dimensi [20].

**Contoh:**

$$\begin{bmatrix} 1 & 2 \\ 2 & 1 \end{bmatrix} = \begin{bmatrix} 1 \\ 2 \\ 2 \\ 2 \end{bmatrix}$$

Tiap-tiap gambar wajah direpresentasikan dengan vektor  $\Gamma_i$ .

$$\Gamma_1 = \begin{bmatrix} 1 \\ -2 \\ 1 \\ -3 \end{bmatrix}, \Gamma_2 = \begin{bmatrix} 1 \\ 3 \\ -1 \\ 2 \end{bmatrix}, \Gamma_3 = \begin{bmatrix} 2 \\ 1 \\ -2 \\ 3 \end{bmatrix}, \dots, \Gamma_m = \begin{bmatrix} 1 \\ 2 \\ 2 \\ 1 \end{bmatrix}$$

*Principal Component Analysis* menggunakan nilai intensitas piksel dari citra yang akan ditampung ke dalam matriks berikut ini [7]:

$$\Gamma = [\Gamma_0 \quad \Gamma_1 \quad \dots \quad \Gamma_{M-1}] \quad (3)$$

Dengan mengasumsikan variabel-variabel, sebagai berikut :

$\Gamma$  : vektor citra *input* berdimensi  $1 \times N^2$

$M$  : jumlah data dari *input* citra

Rata-rata gambar wajah dari semua vektor tau yang dihitung dengan persamaan berikut:

$$\psi = \frac{1}{30} \sum_{i=0}^{M-1} \Gamma_i \quad (4)$$

$$\begin{bmatrix} 1 \\ -2 \\ 1 \\ 3 \end{bmatrix} + \begin{bmatrix} 1 \\ 3 \\ -1 \\ 2 \end{bmatrix} + \begin{bmatrix} 2 \\ 1 \\ -2 \\ 3 \end{bmatrix} + \dots \rightarrow \begin{bmatrix} 1 \\ 2 \\ 2 \\ 1 \end{bmatrix}$$

$$\psi = \frac{(\Gamma_1 + \Gamma_2 + \Gamma_3 + \dots + \Gamma_M)}{M}$$

Dengan mengasumsikan variabel-variabel, sebagai berikut :

$\psi$  : nilai rata-rata citra

$M$  : jumlah dari citra input

$\Gamma$  : *image* vektor berdimensi  $1 \times N^2$

Sehingga diperoleh vektor psi yang berukuran  $N^2 \times M$  [21]

$$\psi = [\psi_1 \quad \psi_2 \quad \dots \quad \psi_M] \quad (5)$$

Semua vektor yang telah diperoleh disimpan ke dalam sebuah matriks bernama “Matriks psi” dalam file “data2”, dimana  $\psi_1, \psi_2, \psi_3, \dots, \psi_{30}$  adalah rata-rata gambar pertama, kedua, ketiga sampai dengan gambar ketiga puluh pada penelitaian ini. Setelah diperoleh nilai *noise* (psi) untuk vektor tau, maka disusun vektor baru phi yang merupakan vektor tau yang bebas *noise* dan dihitung dengan rumus sebagai berikut [16]:

$$\phi_i = \Gamma_i - \psi \quad (6)$$

Tiap-tiap gambar terdiri dari rata-rata dengan  $\Phi = \Gamma_i - \psi$  yang disebut dengan *mean center image*.

$$\Phi_1 = \begin{bmatrix} 2 \\ -1 \\ -1 \\ 0 \end{bmatrix} \Phi_2 = \begin{bmatrix} 2 \\ 4 \\ -3 \\ 5 \end{bmatrix} \Phi_3 = \begin{bmatrix} 3 \\ 2 \\ -4 \\ 6 \end{bmatrix} \dots \Phi_M = \begin{bmatrix} 2 \\ 3 \\ 0 \\ 4 \end{bmatrix}$$

Dengan mengasumsikan variabel-variabel, sebagai berikut :

$\phi$  : jarak perbedaan citra dengan nilai rata-rata citra

$\Gamma$  : vektor citra *input* berdimensi  $1 \times N^2$

$\Psi$  : nilai rata-rata citra

Vektor-vektor yang diperoleh digabung menjadi sebuah matriks berukuran  $1 \times 900$ . Semua vektor yang telah diperoleh disimpan ke dalam sebuah matriks bernama "Matriks A" dalam file "data3". Karena dimensi matriks  $A$  masih cukup besar untuk menghitung determinan matriks digunakan bantuan *software* Matlab untuk menghitungnya dengan syntax  $\chi = \text{eig}(A)$ . Untuk menghitung vektor eigen digunakan rumus sebagai berikut [3]:

$$(\lambda \cdot I - A) \cdot x = 0 \quad (7)$$

Dengan mengasumsikan variabel-variabel, sebagai berikut :

$\lambda$  : nilai eigen

$I$  : matriks identitas

$A$ : matriks kovarians

$x$  : vektor eigen

Matriks *covariance* ( $C$ ) tersebut merupakan matriks persegi yang disimpan ke dalam file "data4".  $A$  adalah matriks kovarian yang dikonstruksikan sebagai berikut  $C = AA^T$

Dimana matriks  $A = [\Phi_1, \Phi_2, \Phi_3, \dots, \Phi_M]$ , dengan ukuran matriks  $N^2 \times N^2$ .

$$A = \begin{bmatrix} 2 & 3 \\ -1 & -2 \\ -1 & 1 \\ 0 & 2 \end{bmatrix}, A^T = \begin{bmatrix} 2 & -1 & -1 & 0 \\ 3 & -2 & 2 & 2 \end{bmatrix}$$

Ukuran matriks kovarians akan menjadi  $N^2 \times N^2$  (matriks berukuran  $30 \times 30$  dipenelitian ini). Vektor eigen yang sesuai dengan matriks kovarians ini perlu dihitung, tetapi itu akan menjadi tugas yang berat. Untuk mempermudah, kami menghitung  $A^T A$  yang akan menjadi matriks  $2 \times 2$  dalam kasus ini [3].

$$A^T A = \begin{bmatrix} 6 & 7 \\ 7 & 18 \end{bmatrix}$$

Diasumsikan eigenvector  $v_i$  dari  $A^T A$ , sehingga

$$A^T A X_i = \lambda_i X_i$$

Vektor eigen  $v_i$  dari  $A^T A$  adalah  $X_1$  dan  $X_2$  berukuran  $2 \times 1$ . Sekarang kalikan kedua ruas  $A$  ke persamaan (), sehingga diperoleh

$$AA^T A X_i = A \lambda_i X_i$$

$$AA^T (A X_i) = \lambda_i (A X_i)$$

Vektor eigen yang sesuai dengan  $AA^T$  sekarang dapat dengan mudah dihitung dengan dimensi tereduksi di mana  $A X_i$  adalah vektor Eigen dan  $\lambda_i$  adalah nilai Eigen.


Tahap ketiga adalah normalisasi yang digunakan untuk menghasilkan *output* pada jaringan saraf tiruan. Pada penelitian ini normalisasi diperoleh dengan mengonversikan nilai *principal component* (*extract*) menjadi nilai bipolar antara  $-1$  sampai dengan  $1$ , hal ini dilakukan karena JST menggunakan nilai input bipolar. Proses konversi ini dinamakan normalisasi yang rumus perhitungannya adalah sebagai berikut :

$$\text{Normalisasi}_i = -1 + \left( \frac{2}{\text{extract}_{\max} - \text{extract}_{\min}} \right) (\text{extract}_i - \text{extract}_{\min}) \quad (8)$$

Semua vektor yang telah diperoleh disimpan ke dalam sebuah matriks bernama "normalisasi" dalam file "data5".

### 2.3. Penggunaan Arsitektur Jaringan saraf *backpropagation*

*Backpropagation* merupakan algoritme pembelajaran yang terawasi dan biasanya digunakan oleh perceptron dengan banyak lapisan untuk mengubah bobot-bobot yang terhubung dengan *neuron-neuron* yang ada pada lapisan tersembunyi. Metode pembelajaran pada jaringan saraf tiruan disebut terawasi jika *output* telah diketahui [2][12].



Gambar 2. Arsitektur Jaringan Saraf *Backpropagation*

Arsitektur jaringan saraf backpropagation 1 *hidden layer* terdiri atas 3 (tiga) lapis (*layer*) yaitu lapisan masukan (*input layer*)  $x_i$ , lapisan tersembunyi (*hidden layer*)  $Z_j$ , dan lapisan keluaran  $y_k$ . *Input layer* dan *hidden layer* dihubungkan dengan penimbangan  $w_{ij}$  dan antara *hidden layer* dan *output layer* dihubungkan dengan  $w_{jk}$ . Pada pelatihan *backpropagation*, ketika jaringan saraf tiruan (JST) diberi pola masukan sebagai pola pelatihan maka pola tersebut akan menuju ke unit pada *hidden layer* untuk diteruskan pada *unit output layer* merupakan *output layer* ( $y_1, y_2, \dots, y_k, y_l$ ). Keluaran sementara pada *hidden layer*  $u_j$  akan diteruskan pada *unit hidden layer* dan *hidden layer* akan memberikan tanggapan yang disebut sebagai keluaran sementara  $u'_k$ . Ketika  $u'_k \neq o_k$ , dimana  $o_k$  adalah keluaran yang diharapkan maka selisih (*error*) *output* sementara  $u'_k$  akan disebarkan mundur (*backward*) pada *hidden layer* yang akan diteruskan ke unit input layer. Oleh karena itu proses tersebut disebut propagasi balik (*backpropagation*) dimana tahap pelatihan dilakukan dengan mengubah penimbangan yang menghubungkan *unit* dalam lapisan JST ketika diberi umpan maju dan umpan balik [22][23].

### 3. HASIL DAN PEMBAHASAN

Setelah dilakukan pelatihan dan pengujian diperoleh hasil penelitian klasifikasi *error* dengan menentukan besar nilai *error* dan tingkat penyimpangan yang secara terakumulasi membentuk pengenalan pola wajah. Sedangkan untuk memudahkan analisa, peneliti menampilkan hasilnya dalam bentuk Grafik 3 dan Tabel 2, sebagai berikut:


#### 3.1. Pelatihan Pola Wajah Pada Jaringan Saraf Tiruan Menggunakan Metode *Principal Component Analysis*

Penelitian pada jaringan saraf *backpropagation* dengan menggunakan metode *Principal Component Analysis* dilakukan berdasarkan penggunaan nilai laju pembelajaran momentum. Hasil penelitian untuk arsitektur jaringan saraf dengan menggunakan PCA adalah sebagai berikut :

**Tabel 2. Hasil Penelitian Menggunakan Metode PCA**

<b>Laju Pembelajaran (<math>\alpha</math>)</b>	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
<b>Momentum (<math>\beta</math>)</b>	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
<b>Epoch</b>	1000	1000	1000	1000	1000	1000	1000	1000	1000
<b>Error</b>	3,0625	0,7057	0,2641	0,1144	0,0527	0,0317	0,0200	0,0138	0,0103
<b>Memorisasi</b>	70%	95%	100%	100%	100%	100%	100%	100%	100%
<b>Generalisasi</b>	60%	60%	70%	70%	70%	100%	50%	60%	60%

Hasil percobaan di atas menunjukkan bahwa kesalahan pelatihan yang dihasilkan dari setiap percobaan terus menurun. Hasil percobaan terbaik dengan nilai *error* terdapat pada laju pembelajaran ( $\alpha$ ) = 0,6 untuk kesalahan pelatihan yang dicapai adalah 0,0317, dengan *epoch* = 1000 kali pengulangan dan kemampuan memorisasi jaringan dan generalisasi jaringan mencapai 100%. Sedangkan untuk melakukan pengamatan terhadap konvergensi jaringan dapat dilakukan melalui pengamatan terhadap Gambar 3, berikut ini:

**Gambar 3. Grafik Pelatihan dengan Metode PCA**

Berdasarkan Gambar 3, dapat dilihat bahwa tingkat konvergensi tertinggi terdapat pada data 6 dan kesalahan pelatihan yang dihasilkan pada setiap *epoch* pelatihan mengalami penurunan.

### 3.2. Pelatihan Pola Wajah Pada Jaringan Saraf Tiruan Tanpa Metode Principal Component Analysis

Proses mengamati pengaruh metode PCA pada jaringan saraf tiruan *backpropagation* pada pengenalan pola wajah pada jaringan saraf tanpa metode PCA. Hasil dari penelitian tersebut adalah sebagai berikut:

**Tabel 3. Hasil Penelitian Tanpa Metode PCA**

<b>Laju pembelajaran (<math>\alpha</math>)</b>	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
<b>Momentum (<math>\beta</math>)</b>	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9
<b>Epoch</b>	485	224	139	98	73	58	41	40	35
<b>Error</b>	0,0100	0,0100	0,0100	0,0100	0,0100	0,0098	0,0100	0,0099	0,0098
<b>Memorisasi</b>	100%	100%	100%	100%	100%	100%	100%	100%	100%
<b>Generalisasi</b>	80%	80%	80%	90%	100%	90%	80%	100%	90%



Hasil percobaan di atas menunjukkan bahwa kesalahan pelatihan yang dihasilkan dari setiap percobaan terus menurun. Hasil percobaan terbaik dengan nilai  $error \leq 0,005$  terdapat pada laju pembelajaran ( $\alpha$ ) = 0,5 untuk kesalahan pelatihan yang dicapai adalah 0,0100, dengan  $epoch = 73$  kali pengulangan dan kemampuan memorisasi jaringan dan generalisasi jaringan mencapai 100%. Sedangkan untuk pengamatan terhadap tingkat konvergensi jaringan dapat dilakukan melalui pengamatan terhadap grafik selama pelatihan pada Gambar 4, berikut ini:



**Gambar 4. Grafik Pelatihan Tanpa PCA**

Berdasarkan grafik Gambar 4. Tingkat konvergensi jaringan selama pelatihan sangat baik karena setiap percobaan mengalami *konvergensi* yang baik sesuai dengan tingkat *error* yang diharapkan dan kesalahan pelatihan pada setiap *epoch* mengalami penurunan.

#### 4. KESIMPULAN

Berdasarkan hasil simulasi pada uraian diatas, maka penelitian ini dapat ditarik kesimpulan:

1. Jaringan saraf tiruan merupakan metode yang baik dalam pengenalan pola wajah karena dapat mencapai kestabilan kembali untuk mencapai *output* yang diharapkan, hal ini karena adanya proses pembelajaran dan pelatihan.
2. Penggunaan metode *principal component analysis* (PCA) dapat mereduksi matriks sesuai dengan jumlah data masukannya.
3. Pada kasus identifikasi pola wajah berdasarkan tingkat memorisasi dan generalisasi lebih baik tanpa menggunakan PCA.
4. Penggunaan *learning rate* dan *momentum* berpengaruh terhadap perubahan *mean square error* (MSE).
5. Semakin kecil tingkat ketelitian error yang digunakan, maka semakin kecil tingkat penyimpangan hasil jaringan saraf tiruan yang diinginkan target.

#### DAFTAR PUSTAKA

- [1] I. Masi, Y. Wu, T. Hassner, and P. Natarajan, "Deep Face Recognition: A Survey," 2019, doi: 10.1109/SIBGRAPI.2018.00067.
- [2] I. kholis and A. Rofii, "Analisis Variasi Parameter Backpropagation Artificial Neural Network Pada Sistem Pengenalan Wajah Berbasis Principal Component Analysis," *J. Kaji. Tek. Elektro*, vol. 2, no. 1, pp. 1–12, 2017.
- [3] Fares Jalled, "Enhanced Reader.pdf," *Nature*, vol. 388, pp. 1–14, 2017, [Online]. Available: <http://arxiv.org/abs/1705.02782>.
- [4] S. Kusmaryanto, "Jaringan Saraf Tiruan Backpropagation untuk Pengenalan Wajah Metode Ekstraksi Fitur Berbasis Histogram," vol. 8, no. 2, pp. 193–198, 2014.

- [5] H. Oliveira and P. L. Correia, "CrackIT - An image processing toolbox for crack detection and characterization," 2014, doi: 10.1109/ICIP.2014.7025160.
- [6] Y. Elviralita and A. Hidayat, "Identifikasi Pola Iris Menggunakan Metode Backpropagation," *Manutech J. Teknol. Manufaktur*, vol. 8, no. 02, pp. 43–48, 2019, doi: 10.33504/manutech.v8i02.21.
- [7] W. Liu, Y. Wen, Z. Yu, M. Li, B. Raj, and L. Song, "SphereFace: Deep hypersphere embedding for face recognition," 2017, doi: 10.1109/CVPR.2017.713.
- [8] A. Vyas, S. Yu, and J. Paik, "Fundamentals of digital image processing," in *Signals and Communication Technology*, 2018.
- [9] F. Hermawan, "Implementasi Jaringan Saraf Tiruan Backpropagation Untuk Mengenali Motif Batik," *Ilm. Komput. dan Inform.*, 2014.
- [10] H. Herman, L. Syafie, and D. Indra, "Pengenalan Angka Tulisan Tangan Menggunakan Jaringan Saraf Tiruan," *Ilk. J. Ilm.*, 2018, doi: 10.33096/ilkom.v10i2.317.201-206.
- [11] A. Sinkov, G. Asyaev, A. Mursalimov, and K. Nikolskaya, "Neural networks in data mining," 2016, doi: 10.1109/ICIEAM.2016.7911596.
- [12] A. Ghaseminejad and V. Uddameri, "Physics-inspired integrated space-time artificial neural networks for regional groundwater flow modeling," *Hydrol. Earth Syst. Sci.*, vol. 24, no. 12, pp. 5759–5779, 2020, doi: 10.5194/hess-24-5759-2020.
- [13] J. O'Rourke and G. T. Toussaint, "Pattern recognition," in *Handbook of Discrete and Computational Geometry, Third Edition*, 2017.
- [14] D. Erhan, C. Szegedy, A. Toshev, and D. Anguelov, "Scalable Object Detection Using Deep Neural Networks," in *2014 IEEE Conference on Computer Vision and Pattern Recognition*, Jun. 2014, pp. 2155–2162, doi: 10.1109/CVPR.2014.276.
- [15] N. Cintisa *et al.*, "Pengenalan Ekspresi Pada Raut Wajah Pada Keselamatan Berkendara Menggunakan Principal Component Analysis ( Pca ) Dan Linear Discriminant Analysis ( Lda ) Facial Emotion Recognition for Safety Driving Using Principal," vol. 6, no. 3, pp. 10292–10300, 2019.
- [16] V. Lopez-Pastor and F. Marquardt, "Self-learning Machines based on Hamiltonian Echo Backpropagation," 2021, [Online]. Available: <http://arxiv.org/abs/2103.04992>.
- [17] V. S. Doan and D. S. Kim, "DOA estimation of multiple non-coherent and coherent signals using element transposition of covariance matrix," *ICT Express*, vol. 6, no. 2, pp. 67–75, 2020, doi: 10.1016/j.ict.2020.03.008.
- [18] N. Das and R. Bhattacharya, "Eigen Value Analysis in Lower Bounding Uncertainty of Kalman Filter Estimates" no. January. pp. 104–107, 2020, [Online]. Available: <http://arxiv.org/abs/2003.06029>.
- [19] R. Vahdani, H. Khalegi Bizaki, and M. J. Fall, "New correlated MIMO radar covariance matrix design with low side lobe levels and much lower complexity," *Chinese J. Aeronaut.*, vol. 34, no. 1, pp. 327–335, 2021, doi: 10.1016/j.cja.2020.08.034.
- [20] F. Nebus and S. Gažovová, "The covariance matrix analysis and statistics for near-field sources localization model," *Adv. Mil. Technol.*, vol. 15, no. 1, pp. 149–162, 2020, doi: 10.3849/aimt.01329.
- [21] Ł. G. Gajewski, J. Chołoniowski, and M. Wilinski, "detected hidden layer.pdf." 2021, [Online]. Available: <http://arxiv.org/abs/2101.11758>.
- [22] N. J. Guliyev and V. E. Ismailov, "Two\_Hidden\_Neurons.Pdf." [Online]. Available: Guliyev, Namig J.%0AIsmailov, Vugar E.