

## PENGENALAN POLA SENYUM MENGGUNAKAN *SELF ORGANIZING MAPS (SOM)* BERBASIS EKSTRAKSI FITUR *TWO-DIMENSIONAL PRINCIPAL COMPONENT ANALYSIS (2DPCA)*

Rima Tri Wahyuningrum<sup>1</sup>, Bahrur Rosyid<sup>2</sup>, Kurniawan Eka Permana<sup>3</sup>

<sup>1,2,3</sup>Program Studi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo Madura  
Jl. Raya Telang Po Box 2 Kamal, Bangkalan 69162, Indonesia  
Telp (031) 3011147, Faks (031) 3011147

E-mail: rima\_tw@yahoo.com, rosyidbahrur@gmail.com, kurnix@yahoo.com

### ABSTRAK

Pengenalan pola senyum merupakan bagian dari *pattern recognition* dan telah banyak dikembangkan. Penelitian ini bertujuan melakukan pengenalan pola senyum menjadi lima macam klasifikasi yaitu: senyum manis, senyum mulut tertutup, senyum mulut terbuka, senyum mengejek, senyum yang dipaksakan. Dua hal yang menjadi masalah utama pada identifikasi pola senyum adalah proses ekstraksi fitur dari sampel pola senyum yang ada dan juga teknik klasifikasi yang digunakan untuk mengklasifikasikan pola senyum yang ingin dikenali berdasarkan fitur-fitur yang telah dipilih. Pada penelitian ini dilakukan proses ekstraksi fitur menggunakan algoritma *Two-Dimensional Principal Component Analysis (2DPCA)*, sedangkan untuk proses klasifikasi menggunakan algoritma *Self Organizing Maps (SOM)*. Berdasarkan hasil uji coba menggunakan 250 data wajah tersenyum, rata-rata akurasi pengenalan pola senyum tertinggi yaitu sebesar 93.36% untuk 30 sampel masing-masing pola senyum.

Kata kunci: pengenalan pola senyum, *2DPCA*, *SOM*

### 1. PENDAHULUAN

Penelitian pengenalan ekspresi wajah telah banyak dilakukan (Matsugu et.al, 2003; Liang et.al, 2005; Kim et.al, 2008; Chen et.al, 2008; Chen et.al, 2009; Moore et.al, 2011). Pola senyum merupakan salah satu bentuk ekspresi wajah. Penelitian ini juga telah banyak dilakukan (Wahyuningrum et.al, 2010; Wahyuningrum dkk, 2011; Huang et.al, 2009). Hal ini disebabkan karena semakin luasnya penggunaan teknik identifikasi pola senyum dalam aplikasi yang digunakan.

Dua hal yang sangat mempengaruhi untuk proses pengenalan adalah penggunaan metode ekstraksi fitur dan klasifikasi. Pada penelitian ini, *2DPCA* digunakan sebagai metode ekstraksi fitur dan *SOM* digunakan sebagai metode klasifikasi atau pengenalan.

*2DPCA* merupakan pengembangan dari metode *PCA*. Metode ini pertama kali dikembangkan Yang et.al, 2004 dengan beberapa kelebihan dibandingkan *PCA* yaitu matrik citra 2D langsung dihitung tanpa mengubah ke bentuk 1D, ukuran matrik kovarian relatif kecil, lebih sederhana dan lebih mudah untuk ekstraksi fitur, tidak membutuhkan *space* vektor citra yang besar, tidak tergantung pada jumlah data. Metode *2DPCA* ini telah banyak dikembangkan antara lain: Kong et.al, 2005; Zuo et.al, 2006; Meng et.al, 2007; Kim et.al, 2008; Lu, 2008; Wang, 2011).

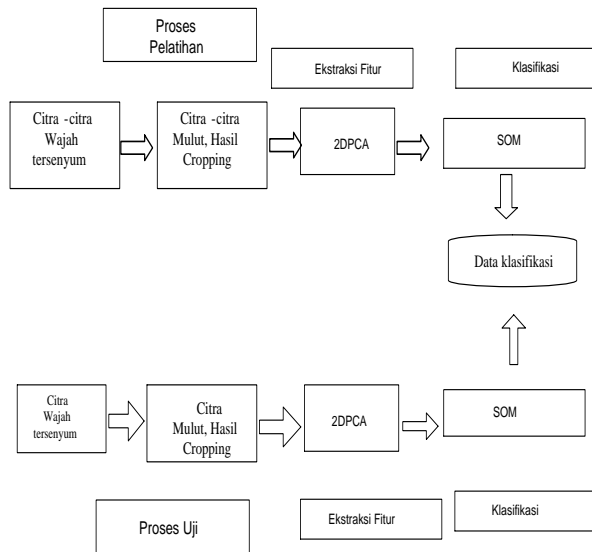
*Self Organizing Maps (SOM)* sebagai metode pengenalan atau klasifikasi termasuk salah satu metode jaringan saraf tiruan. Metode ini termasuk *unsupervised learning*, yaitu tidak ditentukan hasil

luarannya. Selama proses pembelajaran nilai bobot disusun dalam suatu *range* tertentu tergantung pada nilai input yang diberikan. Metode ini juga telah banyak dilakukan untuk *pattern recognition* baik berupa citra maupun data (Banarse et.al, 2000; Gueza et.al, 2006; Ohkubo et.al, 2007; Prieto et.al, 2009; Ghaseminezhad et.al, 2011; Fenga et.al, 2011; Liu et.al, 2011).

### 2. METODE PENELITIAN

#### 2.1 Rancangan Sistem

Pada penelitian ini terdapat tiga modul yaitu *preprocessing* citra wajah tersenyum, ekstraksi fitur, dan pengenalan atau klasifikasi, seperti ditunjukkan pada Gambar 1. Pertama, memasukkan citra wajah tersenyum yang berekstensi *.jpg* ke dalam sistem yang dibangun. Citra *sample* berasal dari 10 orang, tiap-tiap orang diambil lima jenis senyum dan tiap pola senyum diambil lima *sample* senyum yaitu senyum manis, senyum mulut tertutup, senyum mulut terbuka, senyum mengejek, senyum yang dipaksakan. Selanjutnya mengubah citra RGB menjadi *grayscale*, kemudian dilakukan *cropping* pada bagian area mulut. Kedua, untuk mereduksi dimensi citra dilakukan proses ekstraksi fitur menggunakan algoritma *Two-Dimensional Principal Component Analysis (2DPCA)*. Ketiga, fitur-fitur yang dihasilkan pada proses sebelumnya selanjutnya dilakukan proses pengenalan atau klasifikasi menggunakan *Self Organizing Maps (SOM)*.



Gambar 1. Blok diagram rancangan sistem

## 2.2 Algoritma 2DPCA

Berikut ini dijelaskan langkah-langkah dalam penentuan matrik kovarian citra wajah tersenyum terhadap suatu basis data citra pelatihan menggunakan metode 2DPCA:

1. Terdapat himpunan sebanyak  $M$  citra *training* (pelatihan) dari basis data citra wajah tersenyum ( $A_j$ ), dimana  $A_j = [A_{j1}, A_{j2}, \dots, A_{jM}]$ , ( $j = 1, 2, \dots, M$ ) dengan dimensi citra (92 x 112) yang diproyeksikan ke dalam matrik dua dimensi ( $Y$ ).

$$Y = \begin{bmatrix} x_{11} & x_{21} & \dots & x_{M1} \\ x_{12} & x_{22} & \dots & x_{M2} \\ \dots & \dots & \dots & \dots \\ x_{1N} & x_{2N} & \dots & x_{MN} \end{bmatrix} \quad (1)$$

2. Perhitungan rata-rata dari total matrik himpunan pelatihan ( $\bar{A}$ ):

$$\bar{A} = \frac{1}{M} \sum_{j=1}^M Y_j \quad (2)$$

3. Perhitungan matrik selisih dari setiap citra  $A_j$  dengan  $\bar{A}$ :

$$B = A_j - \bar{A} \quad (3)$$

4. Perhitungan matrik kovarian dari himpunan citra pelatihan ( $G_t$ ):

$$G_t = \frac{1}{M} \sum_{j=1}^M (A_j - \bar{A})^T (A_j - \bar{A}) \quad (4)$$

$G_t$  berupa matrik square.

5. Perhitungan *eigenvalue* dan *eigenvektor* dari matrik kovarian menggunakan metode *Singular Value Decomposition* (SVD). Secara matematis dapat diekspresikan sebagai berikut :

$$A\vec{v} = \lambda\vec{v}$$

dimana :

$A$  = square matrik ( $N \times N$ )

$\vec{v}$  = *eigenvektor*

$\lambda$  = skalar / *eigenvalue*

*Eigenvalue* selalu berkorespondensi dengan perubahan *eigenvektor*. Selanjutnya *eigenvektor* diproyeksikan sesuai *eigenvalue* mulai dari yang terbesar  $\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_n$

## 2.3 Algoritma SOM

Di dalam penelitian ini, *SOM* digunakan untuk mengelompokkan pola citra dari hasil ekstraksi fitur dengan metode 2DPCA. Tujuan pembelajaran ini adalah pengelompokan unit-unit yang hampir sama dalam satu area tertentu. Berikut langkah-langkah algoritma *SOM* :

1. Inisialisasi data *input* dari hasil fitur ekstraksi, menentukan *alpha learning rate* dan *Mean Square Error (MSE)*.
2. Inisialisasi bobot awal, menentukan bobot awal secara *random* sebagai parameter awal pada proses komputasi dan inisialisasi jarak tetangga = 0, sebagai asumsi hanya bobot pemenang yang di *update*. Bobot awal dibangkitkan sebanyak unit sebagai asumsi unit adalah informasi pengkluster untuk data *input* setelah mendapatkan bobot optimal dan tiap-tiap unit berisi variabel sebanyak  $1 \times (112 \times 10)$  sebanyak dimensi yang sama dari hasil matrik ekstraksi fitur.
3. *Input* data, yaitu atribut data *training* yang mempengaruhi perubahan bobot pada saat proses komputasi *training* data.
4. Perhitungan jarak terdekat menggunakan metode *Euclidean Distance*, yaitu antara data *input* (vektor) dengan bobot dan node yang memiliki jarak *minimum* antara *input* data dengan *node* bobot dideklarasikan sebagai pemenang. Pencarian jarak terdekat dapat diekspresikan secara matematis ( $d_j$ ):

$$d_j = \sum_{i=0}^{i-1} (X_i(t) - W_{ij})^2 \quad (5)$$

dimana

$d_i$  = jarak

$X_i(t)$  = *Node* data *input*

$W_{ij}$  = Bobot ke-*ij*

5. Melakukan *update* bobot. *Node* bobot pemenang selanjutnya akan di *update* dengan fungsi ini :

$$w_{ij}(t+1) = w_{ij}(t) + \alpha(t) \cdot (x_i(t) - w_{ij}(t)), \quad (6)$$

$j \in N_e$

$0 < \alpha(t) < 1$

dimana

$x_i$  = data *input*

$w_{ij}$  = bobot

$N_e$  = nilai *neighborhood*

$t$  = waktu

$i$  = *index node input*

$j$  = *index node output*

$\alpha$  = *alpha learning rate*

6. Perhitungan *Mean Square Error (MSE)*. *MSE* berfungsi sebagai pengukur kesalahan pembentukan bobot akibat keacakan data selama proses *training*, dimana keacakan data ini akan

mempengaruhi akurasi dari data yang dihasilkan. Selain itu MSE juga berfungsi sebagai ambang batas pada proses komputasi. Dengan menggunakan fungsi kuadrat akar dari *Euclidean Distance* antara bobot awal *epoch* dengan bobot *epoch* sampai memenuhi nilai optimal yang ditentukan, jika MSE belum memenuhi maka proses komputasi 4 dan 5 dilakukan kembali.

7. Perhitungan *update learning rate* dengan pengurangan geometris :

$$\alpha(t + 1) = 0.5 * \alpha(t) \quad (7)$$

8. Jika proses komputasi selesai, simpan bobot hasil komputasi sebagai referensi yang digunakan untuk klasifikasi.

### 3. HASIL DAN PEMBAHASAN

*Database* yang digunakan pada penelitian ini, diambil dari kamera digital sejumlah 250 foto citra wajah tersenyum yang terdiri dari 10 orang dan 5 model senyum yang berbeda dengan masing-masing orang diwakili oleh 25 gambar. Hampir semua gambar mempunyai latar belakang yang cerah dengan ukuran 50 x 50 *pixel*. Kemudian dilakukan *cropping* pada area bibir untuk semua citra wajah tersenyum sehingga ukuran citra menjadi 16 x 40 *pixel*. Sedangkan *tool* yang digunakan pada penelitian ini adalah matlab 2009a.

Pada pengenalan pola, ada dua proses yang dikerjakan yaitu proses pelatihan (*training*) dan proses pengujian (*testing*). Demikian pula, jumlah data citra yang ada dibagi menjadi dua, yaitu data pelatihan dan data pengujian. Data yang sudah digunakan sebagai data pelatihan, tidak boleh digunakan sebagai data pengujian, dan sebaliknya. Uji coba dilakukan dengan mengubah jumlah data pelatihan dan data pengujian, jumlah *eigenvalue* terbesar yang digunakan, nilai *learning rate* ( $\alpha$ ), serta *epoch*, seperti ditunjukkan pada Tabel 1 dan 2.

Tabel 1. Perbandingan hasil akurasi pengenalan pola senyum dengan  $\alpha = 0,01$  dan *epoch* = 100

Jumlah data pelatihan	Jumlah data pengujian	Jumlah <i>eigen value</i> terbesar	Rata-rata akurasi pengenalan (%)
125	125	5	86.50
150	100	5	90.25
175	75	5	93.36
125	125	10	80.25
150	100	10	85.50
175	75	10	89.25
125	125	15	76.30
150	100	15	79.67
175	75	15	82.45

Berdasarkan Tabel 1 terlihat rata-rata akurasi pengenalan tertinggi diperoleh pada saat jumlah data pelatihan = 175, jumlah data pengujian = 75 dan

jumlah *eigenvalue* terbesar yang digunakan = 5, yaitu sebesar 93.36 %, dimana *learningrate* = 0.01 dan *epoch* = 100. Sedangkan berdasarkan Tabel 2 terlihat rata-rata akurasi pengenalan tertinggi diperoleh pada saat jumlah data pelatihan = 175, jumlah data pengujian = 75 dan jumlah *eigenvalue* terbesar yang digunakan = 5, yaitu sebesar 87.25 %, dimana *learningrate* = 0.05 dan *epoch* = 500.

Tabel 2. Perbandingan hasil akurasi pengenalan pola senyum dengan  $\alpha = 0,05$  dan *epoch* = 500

Jumlah data pelatihan	Jumlah data pengujian	Jumlah <i>eigen value</i> terbesar	Rata-rata akurasi pengenalan (%)
125	125	5	80.50
150	100	5	84.65
175	75	5	87.25
125	125	10	73.55
150	100	10	79.00
175	75	10	82.75
125	125	15	70.50
150	100	15	72.25
175	75	15	75.00

Sehingga berdasarkan kedua tabel tersebut, rata-rata akurasi pengenalan tertinggi diperoleh pada saat jumlah data pelatihan = 175, jumlah data pengujian = 75 dan jumlah *eigenvalue* terbesar yang digunakan = 5, yaitu sebesar 93.36 %, dimana *learningrate* = 0.01 dan *epoch* = 100. Berdasarkan kedua tabel tersebut juga terlihat bahwa semakin banyak jumlah data pelatihan yang digunakan, jumlah *eigenvalue* semakin sedikit, *learning rate* semakin kecil menyebabkan hasil rata-rata akurasi pengenalan pola senyum tertinggi.

### 4. KESIMPULAN

Pada penelitian ini telah berhasil melakukan pengenalan pola senyum dengan menggunakan metode ekstraksi fitur 2DPCA dan metode klasifikasi SOM. Berdasarkan hasil penelitian menyatakan bahwa semakin banyak jumlah data pelatihan yang digunakan, jumlah *eigenvalue* semakin sedikit, *learning rate* semakin kecil menyebabkan hasil rata-rata akurasi pengenalan pola senyum tertinggi. Dalam penelitian ini hasil rata-rata akurasi pengenalan tertinggi diperoleh pada saat jumlah data pelatihan = 175, jumlah data pengujian = 75 dan jumlah *eigenvalue* terbesar yang digunakan = 5, yaitu sebesar 93.36 %.

### PUSTAKA

- Liang, D., Yang, J., Zheng, Z., and Chang, Y. (2005). A facial expression recognition system based on supervised locally linear embedding. *Pattern Recognition Letters*, 26, 2374–2389.

- Kim, D. H., Jung, S. U., and Chung, M. J. (2008). Extension of cascaded simple feature based face detection to facial expression recognition. *Pattern Recognition Letters*, 29, 1621–1631.
- Chen, H. Y., Huang, C. L., and Fu, C.M. (2008). Hybrid-boost learning for multi-pose face detection and facial expression recognition. *Pattern Recognition*. 41, 1173 – 1185.
- Fenga, Z., and Xua, T. (2011). Comparison of SOM and PCA-SOM in fault diagnosis of ground-testing bed. *Procedia Engineering*, 15, 1271 – 1276.
- Huang, Y. (2009). *Face Detection And Smile Detection*. Journal Dept. of Computer Science and Information Engineering, National Taiwan University. Diakses 20 Januari 2011 dari <[http://www.csie.ntu.edu.tw/~fuh/personal/Face\\_DetectionandSmileDetection.pdf](http://www.csie.ntu.edu.tw/~fuh/personal/Face_DetectionandSmileDetection.pdf)>
- Geetha, A., Ramalingam, V., Palanivel, S., and Palaniappan, B. (2009). Facial expression recognition – A real time approach. *Expert Systems with Applications*. 36, 303–308.
- Chen., Q. (2009). *Face Recognition Using Self-Organizing Maps*. Diakses 30 Januari 2011 dari <URL:[www.intechopen.com/download/pdf/pdfs\\_id/10464](http://www.intechopen.com/download/pdf/pdfs_id/10464)>
- Matsugu, M., Mori, K., Mitari, Y., and Kaneda, Y. (2003). Subject independent facial expression recognition with robust face detection using a convolutional neural network. *Neural Networks*, 16, 555–559.
- Moore, S., and Bowden, R. (2011). Local binary patterns for multi-view facial expression recognition. *Computer Vision and Image Understanding*, 115, 541–558.
- Wahyuningrum, R.T., Purnomo, M.H., and Purnama, I.K.E., 2010. Smile Stages Recognition in Orthodontic Rehabilitation Using 2DPCA Feature Extraction. *Proceeding of The First International Conference on Green Computing and The Second AUN/SEED-NET Regional Conference on ICT*, Yogyakarta, 214-216.
- Yang, J., Zhang, D., Frangi, A. F., and Yang, J. Y. (2004). Two dimensional PCA : A new approach to appearance-based face representation and recognition, *IEEE Transaction Pattern Analysis Machine Intelligence*, 26 (1), 131-137.
- Wang, H. (2011). Structural two-dimensional principal component analysis for image recognition. *Machine Vision and Applications*, 22, 433–438.
- Lu, C., Liu, W., Liu, X. and An S. (2008). Double Sides 2DPCA for Face Recognition. ICIC 2008, LNCS 5226, 446–459.
- Kim, Y. G., Song, Y. J., Chang, U. D., Kim, D. W., Yun, T. S., and Ahn , J. H. (2008). Face recognition using a fusion method based on bidirectional 2DPCA. *Applied Mathematics and Computation*, 205, 601–607.
- Zuo, W., Zhang , D., and Wang. K., (2006). An assembled matrix distance metric for 2DPCA-based image recognition. *Pattern Recognition Letters*, 27, 210–216.
- Meng, J., and Zhang. W. (2007). Volume measure in 2DPCA-based face recognition. *Pattern Recognition Letters*, 28, 1203–1208.
- Kong, H. Lei, W. Eam K.L. and Xuchun L. (2005). Generalized 2D Principal Component Analysis for Face Image Representation and Recognition. Diakses 5 Mei 2011 dari [URL:http://users.rsise.anu.edu.au/~wangleiMy\\_papers/NN-2DPCA.pdf](http://users.rsise.anu.edu.au/~wangleiMy_papers/NN-2DPCA.pdf)
- Ghaseminezhad, M. H., and Karami, A. (2011). A novel self-organizing map (SOM) neural network for discrete groups of data clustering. *Applied Soft Computing*, 11, 3771–3778.
- Fenga, Z., and Xua, T. (2011). Comparison of SOM and PCA-SOM in Fault Diagnosis of Ground-testing Bed. *Procedia Engineering*, 15, 1271 – 1276.
- Gueza, B. C., Rossib, F., and Gollib, A. E. (2006). Fast algorithm and implementation of dissimilarity self-organizing maps. *Neural Networks*, 19, 855–863.
- Ohkubo, T., Tokunaga, K., and Furukawa, T. (2007). Self-organizing homotopy networks: Comparisons among modular network SOM, SOM of SOMs and parametric bias method. *International Congress Series*, 1301, 168–171.
- Prieto, M. S., and Allen, A. R. (2009). Using self-organising maps in the detection and recognition of road signs. *Image and Vision Computing*, 27, 673–683.
- Banarse, D. S., France, I., and Duller, A. W. G. (2000). Analysis and application of a self-organising image recognition neural network. *Advances in Engineering Software*, 31, 937–944.
- Liu, Y. C., Wu, C., and Liu, M. (2011). Research of fast SOM clustering for text information. *Expert Systems with Applications*, 38, 9325–9333.