

Pengenalan Multi Wajah Berdasarkan Klasifikasi Kohonen SOM Dioptimalkan dengan Algoritma *Discriminant Analysis* PCA

Amir Mahmud Husein¹, Mawaddah Harahap²

^{1,2}Program Studi Teknik Informatika, Fakultas Teknologi dan Ilmu Komputer

Universitas Prima Indonesia

¹amirmahmud@unprimdn.ac.id, ²mawaddah@unprimdn.ac.id

Abstract

Face recognition is a process of identification with the image has variations changeable can be recognized, needs a method of optimization to minimize computational time by not affecting the classification results. This research proposes a face recognition system are directly based on Kohonen SOM classification that optimized by the method of Discriminant Analysis based Principal Component Analysis (PCA). Evaluation of PCA's extraction performance uses two approaches, first the LDA method to optimize PCA issues of the election of irrelevant features of the dataset and the second approach is to apply a kernel function on the LDA (KDA), the results of both approaches are applied on face image classification for Kohonen directly. The testing is two phases, the first stage is testing with a single image of a face and then multi face. Based on the results of testing one face image, both of the approached feature extraction that proposed is very accurately be applied to the classification of the Kohonen SOM with the accurate value of the second approach PCA-KDA is more accurate with 94.22% and the first approach 93.91%, however on the first approach is faster than the second approach with the accurate value of time 0.4 seconds for PCA-LDA and 0.5 seconds to PCA-KDA to one image of the face, but while testing of multi face more two images the result is not significant.

Keywords: Face recognition, Feature extraction, Kohonen SOM.

1. PENDAHULUAN

Pengenalan wajah merupakan salah satu bidang penelitian yang berkembang, hal ini dikarenakan dapat diterapkan dalam berbagai bidang seperti otentifikasi identitas, akses kontrol, interaksi manusia komputer, komersial dan penegakan hukum [1]. Secara umum ada dua pendekatan dalam pengenalan wajah, yaitu berbasis fitur dan secara global [2]. Pendekatan berbasis fitur umumnya diproses dengan mengambil satu set fitur dari gambar (hidung, mata dan lainnya) untuk diklasifikasi, namun dengan pendekatan ini mengekstrak sekumpulan fitur, sehingga kemungkinan sebagian informasi hilang, sedangkan pendekatan secara global menggunakan seluruh gambar sebagai pola untuk diklasifikasi, akan tetapi sangat sensitif terhadap variasi gambar sehingga membutuhkan waktu komputasi yang tinggi untuk identifikasi [2]. Metode ekstraksi fitur wajah seperti *Principal Component Analysis* (PCA) [1], [3]-[7], DCT [8] dan DWT [9] banyak diusulkan peneliti. Metode PCA merupakan salah satu metode klasifikasi yang terbukti akurat dalam pengenalan wajah karena kemampuan untuk mengekstrak struktur global dari sekumpulan data berdimensi tinggi, dengan mengurangi atribut dalam mengolah data [10], namun fitur yang diekstrak secara global, sehingga tidak optimal untuk membedakan satu kelas wajah yang lain. Penerapan kernel pada PCA (KPCA) diusulkan sebagai *non-linier* perluasan dari PCA untuk pengenalan pola [11], yang dapat secara efektif mengekstrak fitur wajah non-linear dengan menghitung komponen utama di ruang non-linier [12]. Namun, model PCA dan KPCA berbasis pada matriks kovariansi, yang mudah terpengaruh oleh *sampel* abnormal dan membuat hasil tidak cukup stabil [13].

Metode *Linier Discriminant Analysis* (LDA) dapat digunakan untuk berbagai aplikasi seperti pengenalan tulisan tangan, wajah, segmentasi citra dan lainnya, LDA mampu meningkatkan pengenalan pola [14], analisis wilayah untuk membedakan satu karakter dengan karakter yang lain [15], namun LDA tidak optimal untuk *multi class* [16]. Penerapan fungsi *kernel* pada LDA (KDA) dapat mengatasi kelemahan *multi class* pada LDA, dengan tingkat akurasi pengenalan yang akurat [17], akan tetapi untuk *sample* yang besar membutuhkan waktu komputasi yang tinggi [18], karena citra wajah memiliki variasi yang dapat berubah-ubah [6]. Oleh karena itu perlu adanya metode untuk optimasi untuk meminimalkan waktu komputasi dengan tidak mempengaruhi hasil klasifikasi. Pada penelitian ini kami menggunakan dua pendekatan ekstraksi fitur wajah. Pendekatan pertama menerapkan metode LDA berbasis ekstraksi fitur PCA, sedangkan pendekatan kedua menerapkan fungsi *Kernel* pada LDA (KDA) berbasis PCA, untuk klasifikasi *multiwajah* menggunakan metode

Kohonen SOM secara *online*. Kohonen SOM merupakan salah satu metode *unsupervised network* yang mana suatu proses *self-organizing* dimulai dengan pemilihan bobot node secara acak pada Kohonen layer, SOM terbukti akurat dalam pengenalan wajah [19]-[20], [3]. Paper ini disajikan sebagai berikut: bab 2 penelitian terkait dan bab 3 metode yang diusulkan. Bab 4 pembahasan dan bab 5 kesimpulan.

2. PENELITIAN TERKAIT

Pada penelitian Himaanshu Gupta et al. [2] membandingkan metode LDA/KDA dengan PCA/KPCA untuk pengenalan wajah Yale bersumber UMIST. Hasil pengujian, metode LDA/KDA lebih unggul dibandingkan metode PCA/KPCA, penerapan fungsi *kernel* dapat mengatasi dimensi ruang yang besar, namun penerapan *kernel* tidak selalu memastikan berkinerja lebih baik bahkan akan menurunkan kinerja jika masalah *linier*. M. Kawulok, Jolanta, J. Nalepa [21], melakukan penelitian deteksi kulit dengan pengembangan skema penggabungan analisa spasial dengan permodelan kulit adaptif menerapkan metode *distance transform* (DT) untuk memecahkan masalah LDA yang terbatas pada wilayah ukuran *kernel* besar. Pada penelitian F. Z. Chelali, A. Djeradi dan N. Cherabit [3], mengusulkan metode *discrete cosine transform* (DCT) untuk karakteristik wajah dan metode PCA untuk pengurangan spasial, sedangkan kohonen SOM digunakan untuk pengenalan wajah dengan membandingkan DCT dengan DCT+PCA terhadap kohonen SOM untuk karakteristik wajah terhadap tiga database berbeda, hasil pengujian kombinasi DCT Kohonen lebih akurat.

3. METODE YANG DIUSULKAN

Pada penelitian ini menggunakan pendekatan yang berbeda untuk mengoptimalkan kelemahan PCA dengan menerapkan LDA/KDA, hasilnya kelas dijadikan sebagai parameter masukan Kohonen SOM untuk klasifikasi multi wajah secara langsung. Berikut penjelasan metode yang diusulkan.

3.1 Metode PCA

Penerapan PCA untuk proses segmentasi sedangkan LDA/KDA untuk ekstraksi fitur wajah. digunakan proses *preprocessing*, segmentasi dan normalisasi dengan tahapan sebagai berikut:

1. Pembuatan T metrik citra
 $[T]=(M*N)*total_sample$ (1)
2. Menghitung matrik *mean*
 $Mean[T]=Sum(T_training)/N$ (2)
3. Hitung matrik normalisasi
 $[A]=[T]-mean$ (3)

Metode PCA pada dasarnya memutar sekumpulan point disekitar rata-rata agar dapat menyesuaikan dengan komponen utama, metode ini mengerakkan *varians* sebanyak mungkin dengan menggunakan *transformasilinier* kedalam beberapa dimensi. Kelemahan PCA dalam penentuan fitur yang tidak relevan dengan dataset, yang kemungkinan fitur yang dibuang merupakan fitur yang berpengaruh, sehingga untuk ekstraksi fitur digunakan metode LDA/KDA.

3.2 Metode LDA dan KDA

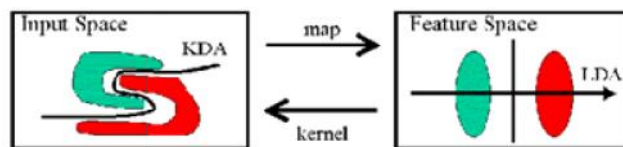
Metode LDA adalah metode pembelajaran yang diawasi dengan memanfaatkan kategori informasi yang terkait dari masing-masing *sampel*, tujuan LDA untuk memaksimalkan penyebaran kelas antar kelas dengan meminimalkan kelas yang tersebut, penyebaran kelas didefinisikan sebagai berikut:

$$S_w = \sum_{j=1}^c \sum_{i=1}^{N_j} (x_i^j - \mu_j)(x_i^j - \mu_j)^T$$

$$S_b = \sum_{j=1}^c (\mu_j - \mu)(\mu_j - \mu)^T$$
(4)

dimana x_{ij} adalah sampel ke-i dari kelas j, μ_j adalah mean dari kelas j, μ adalah citra rata-rata dari semua kelas, c adalah jumlah kelas, dan N_j adalah jumlah sampel kelas j.

Prinsip dasar metode KDA diilustrasikan pada gambar 1, penerapan fungsi *kernel* untuk mengatasi kelememahan sifat *non-linier* yang sulit untuk menghitung secara langsung ciri-ciri distriminatif antara dua kelas pola ruang masukan (citra), sehingga perlu dilakukan pemisahan fitur citra secara *linier*.



Gambar 1. Kernel Discriminant Analysis.


Pada gambar 1, merupakan citra masukan yang perlu dilakukan distribusi yang dipisahkan secara linier ke ruang fitur dengan berdasarkan pemetaan *non-linier* dari ruang input ke ruang fitur dimensi tinggi (kanan). Dengan menerapkan fungsi *kernel* yang sesuai dengan pemetaan *non-linier*, masalah dekomposisi *eigen* dapat diselesaikan. Penerapan *kernel*, operasi LDA yang awalnya *linier* dilakukan pemetaan ruang fitur dimensi tinggi dengan pemetaan *non-linier* dengan tujuan untuk menemukan transformasi yang memaksimalkan *varians* kelas antara dan meminimalkan *varians* dalam kelas dengan persamaan:

$$J(\alpha) = \frac{\alpha^T S_B \alpha}{\alpha^T S_W \alpha} \quad \text{Menjadi} \quad S_B = \sum_{c=1}^C (\mu_c - \bar{x})(\mu_c - \bar{x})^T \quad S_W = \sum_{c=1}^C K_c (I - 1_c) K_c^T \quad (5)$$

Dimana K_c adalah matriks *kernel* untuk kelas c , u_c adalah kolom yang berarti vektor untuk K_c I adalah matriks identitas, l_c adalah jumlah sample di kelas c dan $1/l_c$ adalah matriks $l_c \times l_c$ dengan semua entri $1/l_c$.

3.3 Kohonen SOM

Kohonen *Classifier Self-Organizing Maps* (SOM) diperkenalkan oleh orang Finlandia Profesor Teuvo Kohonen pada tahun 1982, SOM merupakan jenis jaringan saraf tiruan yang dilatih menggunakan pembelajaran tanpa pengawasan untuk menghasilkan representasi dimensi sampel pelatihan yang rendah. Metode Kohonen tidak menggunakan fungsi aktivasi dan bobot bias [22]. Jaringan kohonen mampu menyusun diri sendiri berdasarkan nilai masukan tertentu dalam suatu kelompok yang disebut cluster dan pembentukan cluster, keluaran dari metode ini berdasarkan suatu pola yang dimasukkan dan akan dipilih sebagai pemenang, neuron-neuron pemenang akan mewakili suatu kumpulan data yang akan dikenali jaringan SOM [23]. Dalam penelitian ini metode jaringan saraf tiruan Kohonen diterapkan untuk mengklasifikasi vektor berbasis PCA ke dalam kelompok neuron sehingga dapat mengenali masing-masing wajah dari total dataset yang diuji. SOM dapat digunakan untuk mendeteksi fitur yang melekat untuk masalah ini disebut dengan SOFM (*Self-Organizing Feature Map*). Arsitektur SOM terdiri dari 1 lapisan *input* dan 1 lapisan *output*. Setiap unit pada lapisan input dihubungkan dengan semua unit di lapisan output dengan suatu bobot keterhubungan w_{ij} .



Gambar 2. Arsitektur Kohonen SOM

Algoritma Pembelajaran

Langkah 0 : - Inisialisasi bobot w_{ij} .

✓ Set parameter topological neighborhood

✓ Set parameter laju pembelajaran α .

Langkah 1 : Jika syarat berhenti tidak dipenuhi (Salah), Kerjakan langkah 2 – 8

Langkah 2 : Untuk setiap input vektor x , kerjakan langkah 3 – 5

Langkah 3 : Untuk setiap indeks j , hitung nilai :

$$D(j) = \sum_i (w_{ij} - x_i)^2 \quad (1)$$

Langkah 4 : Cari unit pemenang (indeks J), yaitu unit yang memiliki $D(j)$ minimum.

Langkah 5 : Hitung semua nilai w_{ij} (baru) dengan nilai j dari langkah 4

$$w_{ij}(\text{baru}) = w_{ij}(\text{lama}) + \alpha [x_i - w_{ij}(\text{lama})] \quad (2)$$

Langkah 6 : Ubah (*update*) nilai laju pembelajaran.

Langkah 7 : Kurangi jarak tetangga (R).

Langkah 8 : Periksa syarat berhenti

Algoritma Pengenalan

Langkah 0 : Set nilai bobot w_{ij} .(ambil dari hasil pembelajaran)

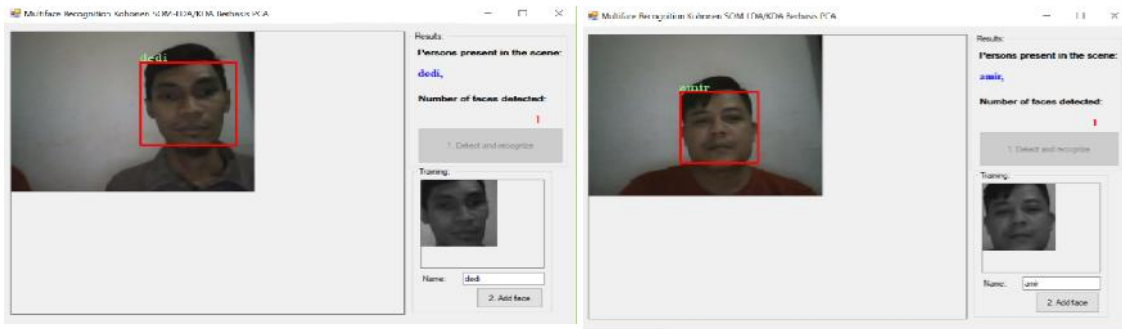
Langkah 1 : Untuk setiap indeks j, hitung nilai :

$$D(j) = \sum_i (w_{ij} - x_i)^2 \tag{3}$$

Langkah 2: Cari unit pemenang (indeks J), yaitu unit yang memiliki D(j) minimum.

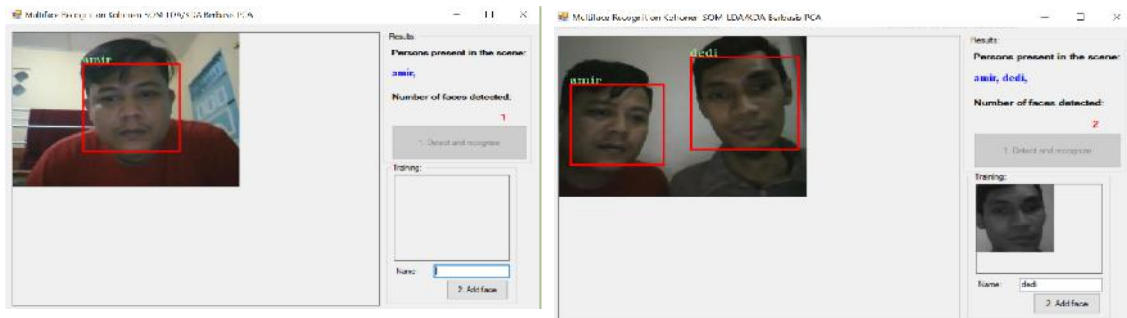
4. HASIL DAN PEMBAHASAN

Percobaan dilakukan dengan spesifikasi platform intel core i5 2,5 GHz CPU, 8 Gb RAM dan menggunakan sistem operasi WIN 10 64 bits, aplikasi dibuat menggunakan C# 2010 dengan kombinasi framework Accord.NET yang merupakan pengembangan dari framework AForge.Net. Untuk pengujian pengenalan multi wajah, tahap pertama dilakukan proses pengambilan wajah untuk pelatihan. Pengambilan wajah menggunakan webcam kemudian dimasukkan nama citra wajah, sistem akan melakukan segmentasi wajah, dengan menerapkan dua pendekatan ekstraksi fitur wajah, tahap pertama kombinasi PCA+LDA, sedangkan pendekatan kedua PCA+KDA, hasil kedua pendekatan diterapkan pada metode klasifikasi Kohonen SOM, untuk dilakukan analisa perbandingan yang paling akurat untuk identifikasi dan yang optimal dari sisi waktu ekstraksi wajah. kedua metode ekstraksi ini akan dijadikan sebagai parameter masukan Kohonen SOM dengan menentukan nilai *threshold* =0,5. *Learning rate* yang digunakan adalah =0,3. Bobot awal yang dipilih $w_1=0,01$ dan $w_2=0,02$. Maksimum *epoch*=50, nilai *error* diperoleh dari nilai t-y. Pelatihan jaringan saraf tiruan ini berfungsi untuk mengajarkan pola-pola wajah yang ada sehingga diharapkan jaringan dapat mengenali pola-pola baru. Pada gambar 3 contoh pengambilan citra wajah latih.



(a) (b)
Gambar 3. (a) dan (b) proses pengambilan wajah dan pelatihan

Pada gambar 3, data wajah yang dilatih sebanyak 20 citra wajah dengan masing-masing wajah diambil 5 citra posisi berbeda, sehingga total data latih wajah sebanyak 100 citra wajah untuk dilatih sedangkan pada tahap pengujian digunakan 10 citra wajah dengan masing-masing diambil 3 citra wajah, hasil pengujian ditampilkan pada gambar 4.

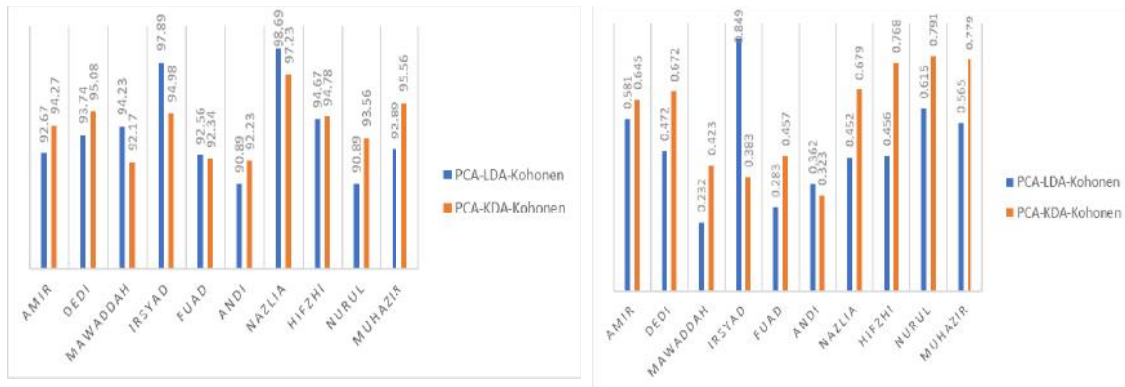


(a) (b)
Gambar 4 (a) Pengujian satu wajah, (b) multi wajah

Pada gambar 4 (a) merupakan pengujian pengenalan wajah dengan menggunakan satu wajah, sedangkan gambar 4 (b) dilakukan pengujian multi wajah secara langsung pada aplikasi yang dibangun dengan menggunakan pendekatan ekstraksi PCA-LDA/KDA berbasis klasifikasi Kohonen SOM. Hasil pengujian dua pendekatan ekstraksi wajah terhadap akurasi waktu dan identifikasi terhadap metode klasifikasi Kohonen SOM. Pengujian wajah dengan kedua pendekatan ini kami terapkan untuk pengenalan wajah dan multi wajah, hasil kedua pengujian terdapat perbedaan dimana pada saat pengujian multi wajah kedua pendekatan tidak terlalu signifikan mengenal dibandingkan pengujian dengan satu wajah. Untuk lebih jelasnya hasil pengujian satu wajah dapat dilihat pada tabel 1 dan tabel 2 hasil pengujian multi wajah.

Tabel 1. Hasil klasifikasi wajah

No	Nama Citra	Jumlah Citra Wajah	Iterasi	Akurasi Identifikasi		Waktu (t)	
				PCA-LDA-Kohonen	PCA-KDA-Kohonen	PCA-LDA-Kohonen	PCA-KDA-Kohonen
1	amir	3	5	92.67	94.27	0.581	0.645
2	dedi	3	5	93.74	95.08	0.472	0.672
3	mawaddah	3	5	94.23	92.17	0.232	0.423
4	irsyad	3	5	97.89	94.98	0.849	0.383
5	fuad	3	5	92.56	92.34	0.283	0.457
6	andi	3	5	90.89	92.23	0.362	0.323
7	nazlia	3	5	98.69	97.23	0.452	0.679
8	hifzhi	3	5	94.67	94.78	0.456	0.768
9	nurul	3	5	90.89	93.56	0.615	0.791
10	muhazir	3	5	92.89	95.56	0.565	0.779



Gambar 5 (a) Akurasi Klasifikasi, (b) Akurasi Waktu

Pada tabel 1, merupakan hasil pengujian wajah dengan jumlah sebanyak 10 dengan masing-masing diambil 3 citra wajah untuk dilakukan pengujian dengan jumlah iterasi 5, *threshold* =0,5. *Learning rate* yang digunakan adalah =0,3. Bobot awal yang dipilih $w_1=0,01$ dan $w_2=0,02$. Maksimum *epoch*=50. Hasil pengujian terdapat perbedaan nilai akurasi identifikasi dan waktu terhadap kedua pendekatan ekstraksi fitur citra wajah, pendekatan PCA-KDA-Kohonen lebih akurat untuk klasifikasi dengan nilai rata-rata akurasi 94,22%, sedangkan PCA-LDA-Kohonen akurasi waktu lebih cepat dengan 0,4 detik untuk klasifikasi satu wajah, sedangkan klasifikasi untuk multi wajah ditunjukkan pada tabel 2.

Tabel 2. Hasil klasifikasi multi wajah

No	Data	Jlh Citra Uji	nama citra	PCA-LDA-Kohonen		Waktu (t)	PCA-KDA-Kohonen		Waktu (t)
				Hasil Klasifikasi	Akurasi		Hasil Klasifikasi	PCA-KDA-Kohonen	
1	uji1	2	amir, dedi	2	97.78	0.990	2	98.85	1.360
2	uji2	2	lolo, mawaddah	1	67.34	0.920	2	85.67	1.110
3	uji3	3	nazlia, fuad, siti	2	75.67	1.190	1	45.21	1.470
4	uji4	2	dedi, mawaddah	2	96.82	1.090	2	97.91	0.980
5	uji5	3	nazlia, irsyad, dedi	3	97.69	1.130	2	85.78	1.410
6	uji6	2	irsyad, muhajir	1	62.89	1.200	2	89.42	0.940
7	uji7	3	evi, rivai, nazlia	2	77.69	0.910	3	96.34	1.360
8	uji8	2	muhajir, nurul	2	95.67	1.170	2	96.43	1.040
9	uji9	3	rozi, amru, andi	2	81.23	0.970	2	83.45	0.980
10	uji....	3	siti, soflan, winda	1	45.67	0.910	2	81.98	1.500

Pada tabel 2, merupakan hasil pengujian citra wajah berdasarkan klasifikasi Kohonen SOM dengan dua pendekatan ekstraksi pada multi wajah, terdapat perbedaan hasil dibandingkan pada pengujian satu wajah, dimana pada pengujian multi wajah hasil tidak optimal apabila diuji secara langsung lebih dari dua citra. Pendekatan pertama menghasilkan nilai akurasi 79,85% dengan 0,72 hasil klasifikasi dari total citra uji, sedangkan pendekatan kedua nilai akurasi 86,10% dengan 0,80 hasil klasifikasi. untuk akurasi waktu identifikasi pendekatan pertama lebih cepat dengan 1,05 detik dibandingkan pendekatan kedua dengan 1,22 detik untuk klasifikasi multi wajah.

5. KESIMPULAN

Pada penelitian ini menggunakan dua pendekatan untuk mengoptimalkan kelemahan metode ekstraksi fitur PCA dengan menerapkan LDA dan KDA, berdasarkan hasil pengujian, secara keseluruhan kedua pendekatan yang diusulkan sangat akurat terhadap klasifikasi Kohonen SOM untuk pengenalan wajah dengan nilai akurasi diatas 90%, akan tetapi pendekatan dengan menggunakan PCA-KDA lebih akurat dibandingkan dengan pendekatan PCA-LDA terhadap klasifikasi Kohonen, namun akurasi waktu pendekatan PCA-LDA lebih cepat dibandingkan dengan PCA-KDA. Pengujian multi wajah secara langsung tidak terlalu optimal pada klasifikasi Kohonen SOM khususnya apabila dilakukan pengujian lebih dari dua citra secara langsung. Pada pendekatan pertama nilai akurasi 0,72 % hasil klasifikasi dan 0,80% pada pendekatan kedua dari total citra wajah yang diuji, dari hasil ini perlu dilakukan penelitian lanjut dengan menerapkan metode ekstraksi fitur yang lain seperti DWT dan DCT.

UCAPAN TERIMA KASIH

Kami mengucapkan terima kasih kepada semua pihak yang bekerja sama dan memberikan berkontribusi pada penelitian ini khususnya pada teman-teman sejawat di Universitas Prima Indonesia, khususnya Lembaga Penelitian dan Pengabdian UNPRI serta kepala Laboratorium UNPRI yang telah memberikan waktu dan tempat dalam penelitian ini.

BAHAN REFERENSI

- [1] Jyotsna, N. Rajpal, V. P. Vishwakarma, 2016, "Face recognition using Symlet, PCA and Cosine angle distance measure", *Conference: 2016 Ninth International Conference on Contemporary Computing (IC3)*, India, August 2016.
- [2] H. Gupta, A. K. Agrawal, T. Pruthi, C. Shekhar, and R. Chellappa, 2002, "An Experimental Evaluation of Linear and Kernel-Based Methods for Face Recognition", *Proceedings of the Sixth IEEE Workshop on Applications of Computer Vision*, 0-7695-1858-03.

- [3] F. Z. Chelali, A. Djeradi, and N. Cherabit, 2015, "Investigation of DCT/PCA combined with Kohonen classifier for human identification", 978-1-4673-6673-1.
- [4] V. AlEnzi, M. AlFiras, and F. Alsaqre, "Face Recognition Algorithm Using Two Dimensional Principal Component Analysis Based on Discrete Wavelet Transform", V. Snasel, J. Platos, and E. ElQawasmeh (Eds.): ICDIPC 2011, Part I, CCIS 188, pp. 426–438, 2011. © Springer-Verlag Berlin Heidelberg 2011.
- [5] M. P. Satone, and G. K. Kharate. "Face recognition based on PCA on Wavelet subband of average-half-face." *Journal of Information Processing Systems* 8.3 (2012): 483-494.
- [6] Z. Liu, X. Lu, 2011, "Face Recognition Based on Fractional Fourier Transform And PCA", 978-1-4244-9793-5. 1406-1410.
- [7] E. Gumus, N. Kilic, A. Sertbas, and O. N. Ucan, 2010, "Evaluation of face recognition techniques using PCA, wavelets and SVM", *Expert Systems with Applications* 37 (2010) 6404–6408. doi: 10.1016/j.eswa.2010.02.079. Elsevier.
- [8] Vishwakarma, Virendra P. "Illumination normalization using fuzzy filter in DCT domain for face recognition." *International Journal of Machine Learning and Cybernetics* 6.1 (2015): 17-34.
- [9] Nicholl, Paul, A. Ahmad, and A. Amira, 2010, "Optimal discrete Wavelet transform (DWT) features for face recognition." *Circuits and Systems (APCCAS)*, 2010 IEEE Asia Pacific Conference on. IEEE.
- [10] W. Y. Zhao, R. Chellappa, A. Rosenfeld, and P. J. Phillips, 2000, "Face recognition: A literature survey", UMD CfAR Technical Report CAR-TR-948.
- [11] K.I. Kim, K. Jung and H. J. Kim, 2002, "Face Recognition Using Kernel Principal Component Analysis", *IEEE Signal Processing letters*, Vol 9, No. 2.
- [12] W. Lei, 2009, "Research on global statistic and local geometry based dimensionality reduction algorithm", University of Science and Technology of China, Beijing, China.
- [13] Xiaoli Ruan, Shunfang Wang. 2017, "Face Recognition based on Weighted Multi-Resolution Kernel Entropy Component Analysis", 978-1-5090-4657-7. 6118- 6123
- [14] T. F. Gao, C. L. Liu, 2008, "High accuracy handwritten Chinese character recognition using LDA-based compound distances", *Pattern Recognition* 41 (11), 3442–3451.
- [15] Tao, D., Liang, L., Jin L., & Gao, Y. 2014, "Similar handwritten Chinese character recognition by kernel discriminative locality alignment", *Pattern Recognition Letters* 35 (2014) 186–194.
- [16] Yao, C., Lu, Z., Li, J., Xu, Y., & Han, J. (2014). A subset method for improving Linear Discriminant Analysis. *Neurocomputing*, 138, 310–315.
- [17] J. Gui, Z. Sun, J. Cheng, S. Ji, and X. Wu, 2014 "How to Estimate the Regularization Parameter for Spectral Regression Discriminant Analysis and its Kernel Version?", *IEEE Transactions on Circuits and Systems for Video Technology*, VOL. 24, NO. 2.
- [18] Fan, Z., Xu, Y., Ming Ni a, Fang, X., & Zhang, D. 2016. Individualized learning for improving kernel Fisher discriminant analysis. *Pattern Recognition* 58 (2016) 100–109.
- [19] Y. Kun, Z. Hong, P. Ying-jie, 2006 "Human Face Detection Based on SOFM Neural Network" *Proceedings of the 2006 IEEE International Conference on Information Acquisition*. 1253-1257.
- [20] A Majumder, L Behera and V. K. Subramanian, 2014, "Local Binary Pattern based Facial Expression Recognition using Self-Organizing Map", *International Joint Conference on Neural Networks (IJCNN)*. 2375-2382.
- [21] M. Kawulok, J. Kawulok, J. Nalepa, 2014, "Spatial-based skin detection using discriminative skin-presence features", *Pattern Recognition Letters*. 3–13.
- [22] Qiu Chen, Koji Kotani, Feifei Lee and Tadahiro Ohmi. "Face Recognition Using Self-Organizing Maps, Self-Organizing Maps", George K Matsopoulos (Ed.), ISBN: 978-953-307-074-2, 2010, InTech, Available from: <http://www.intechopen.com/books/self-organizingmaps/face-recognition-using-self-organizing-maps>.
- [23] Keerti Keshav Kanchia and Vijaya Ca, 2013 "Real Time Facial Expression Recognition System Using 2D-DCT and Neural Network", *International Journal of Current Engineering and Technology*, 280-287. ISSN 2277 – 4106