

Kombinasi *KPCA* dan *Euclidean Distance* untuk Pengenalan Citra Wajah

Rima Tri Wahyuningrum

^{1,2}Prodi Teknik Informatika, Fakultas Teknik, Universitas Trunojoyo

Jl. Raya Telang, PO BOX 2 Kamal, Bangkalan

E-mail: r_tw@yahoo.co.id

Abstrak

Permasalahan *machine learning* dan *pattern recognition* bukan merupakan penelitian yang baru. Seiring dengan perkembangan teknologi, semakin berkembang pula teknik dan algoritma yang digunakan untuk menyelesaikan permasalahan *machine learning* dan *pattern recognition*. Pada penelitian ini telah berhasil melakukan pengenalan citra wajah menggunakan ekstraksi fitur *Kernel Principal Component Analysis (KPCA)* untuk menentukan karakteristik dari wajah dan *Euclidean Distance* sebagai metode klasifikasi berbasis statistik. Sedangkan uji coba telah dilakukan pada basis data citra wajah ORL, YALE dan BERN menggunakan kernel polynomial dan Gaussian, dengan reduksi dimensi menjadi $v = 25$ dan $v = 50$. Akurasi pengenalan citra wajah tertinggi dari ketiga basis data tersebut adalah menggunakan kernel Gaussian dan reduksi dimensi $v = 50$ dengan tujuh data pelatihan di setiap kelasnya. Pada basis data citra wajah ORL diperoleh akurasi pengenalan sebesar 98,50%, pada basis data citra wajah YALE diperoleh akurasi pengenalan sebesar 97,65%, dan pada basis data citra wajah BERN diperoleh akurasi pengenalan sebesar 97,95%. Dengan demikian, metode ekstraksi fitur *KPCA* yang dikombinasikan dengan metode klasifikasi *Euclidean Distance* sangat baik digunakan sebagai pengenalan citra wajah.

Kata kunci: *Kernel Principal Component Analysis (KPCA)*, *Euclidean Distance*, kernel polynomial, kernel Gaussian

Abstract

Problems of machine learning and pattern recognition are not a new research. Along with the development of technology, growing techniques and algorithms used to solve the problems of machine learning and pattern recognition. In this research has been successfully performed face recognition using Kernel Principal Component Analysis (KPCA) as feature extraction to determine the characteristics of the face and Euclidean Distance as the classification method based on statistics. While the experiments have been conducted on ORL face image database, YALE and BERN using polynomial and Gaussian kernel, the dimension reduction to $v = 25$ and $v = 50$. Highest recognition accuracy of three face image database is to use the Gaussian kernel and the reduction of dimension $v = 50$ with seven training data in each class. In the ORL face image database obtained recognition accuracy of 98,50%, on the basis of image data obtained YALE face recognition accuracy of 97,65%, and on the basis of image data obtained BERN face recognition accuracy of 97,95%. Thus, KPCA feature extraction methods are combined with Euclidean Distance classification method is best used as a facial image recognition.

Key words: *Kernel Principal Component Analysis (KPCA)*, *Euclidean Distance*, polynomial kernel, Gaussian kernel

Pendahuluan

Penelitian tentang pengenalan wajah terus berkembang seiring dengan kemajuan teknologi. Aplikasi ini sangat

bermanfaat untuk absensi karyawan dan mengenali pelaku tindak kriminalitas.

Pengenalan wajah merupakan bagian dari *pattern recognition*. Secara garis besar terdapat tiga tahapan dalam melakukan ini yaitu pra pemrosesan, ekstraksi fitur dan klasifikasi. Pada penelitian ini tidak melakukan tahap pra pemrosesan karena data yang digunakan yaitu ORL, YALE dan BERN telah dilakukan pra

pemrosesan sehingga data tersebut dapat langsung dilakukan proses berikutnya. Oleh karena itu, metode yang digunakan untuk ekstraksi fitur dan klasifikasi sangat menentukan dalam penelitian ini.

Pada penelitian sebelumnya metode ekstraksi fitur yang paling banyak diminati para peneliti adalah *Principal Component Analysis (PCA)* [1] dan *Linear Discriminant Analysis (LDA)* [2]. PCA seringkali mengalami kesulitan untuk memodelkan data yang sangat kompleks. Kernel *PCA (KPCA)* merupakan pengembangan non-linear dari PCA. Dengan menggunakan representasi non-linear data pada *KPCA* akan lebih mudah dimodelkan [3]. Penelitian tentang

KPCA pada pengenalan pola (*pattern recognition*) telah banyak dilakukan [4-8].

Sedangkan metode klasifikasi untuk menentukan kelas dapat menggunakan metode berbasis statistik maupun berbasis Jaringan Syaraf Tiruan (JST). Pada penelitian ini, menggunakan metode klasifikasi berbasis statistik yaitu *Euclidean Distance* [9-10].

Oleh karena itu, pada penelitian ini telah berhasil mengimplementasikan kombinasi KPCA dan *Euclidean Distance* pada pengenalan citra wajah.

Metode

Secara umum pengenalan citra wajah terdiri dari dua proses yaitu proses pelatihan dan pengujian. Masing-masing proses ini melakukan ekstraksi fitur KPCA untuk mendapatkan matrik bobot kemudian menghitung klasifikasi berbasis statistik menggunakan *Euclidean Distance*. Selanjutnya diperoleh hasil akurasi pengenalan citra wajah. Data yang digunakan pada penelitian ini adalah basis data citra wajah ORL, YALE dan BERN. Gambar 1 menunjukkan diagram alir rancangan sistem pengenalan citra wajah.

Algoritma Kernel Principal Component Analysis (KPCA)

PCA tradisional hanya memungkinkan reproduksi pada dimensi linier. Namun, jika data memiliki struktur lebih rumit, yang tidak dapat disederhanakan dalam ruang sub-linear, maka PCA tradisional akan menjadi tidak valid. Oleh karena itu, kernel PCA memungkinkan untuk menggeneralisasi tradisional PCA dengan tujuan pengurangan dimensi nonlinear [3].

Berikut ini dijelaskan Algoritma KPCA [11]: Pertama diasumsikan bahwa fitur baru diproyeksikan memiliki *zero mean*, seperti ditunjukkan pada Persamaan 1:

$$= \sum_{\alpha} \varphi(x_{\alpha}) = 0.$$

Matrik kovarian dari fitur proyeksi, $M \times M$, dihitung berdasarkan Persamaan 2:

$$G = \frac{1}{N} \sum_{\alpha=1}^N \varphi(x_{\alpha})\varphi(x_{\alpha})^T, \tag{2}$$

sedangkan *eigenvalues* dan *eigenvectors* dihitung berdasarkan Persamaan 3:

$$Gv_j = \lambda_j v_j, \tag{3}$$

dengan $j = 1, 2, \dots, M$. Dari Persamaan 2 dan Persamaan 3 diperoleh Persamaan 4 yaitu:

$$\frac{1}{N} \sum_{\alpha=1}^N \varphi(x_{\alpha})\{\varphi(x_{\alpha})^T v_j\} = \lambda_j v_j. \tag{4}$$

Selanjutnya ditulis menjadi Persamaan 5:

$$v_j = \sum_{\alpha=1}^N r_{j\alpha} \varphi(x_{\alpha}) \tag{5}$$

Kemudian mensubstitusikan v_j pada Persamaan 4 dengan Persamaan 5, sehingga diperoleh Persamaan 6:

$$\frac{1}{N} \sum_{\alpha=1}^N \varphi(x_{\alpha})\varphi(x_{\alpha})^T \sum_{b=1}^N r_{jb} \varphi(x_b) = \lambda_j \sum_{\alpha=1}^N r_{j\alpha} \varphi(x_{\alpha}). \tag{6}$$

Berikutnya mendefinisikan fungsi kernel seperti ditunjukkan pada Persamaan 7:

$$l(x_a, x_b) = \varphi(x_a)^T \varphi(x_b), \tag{7}$$

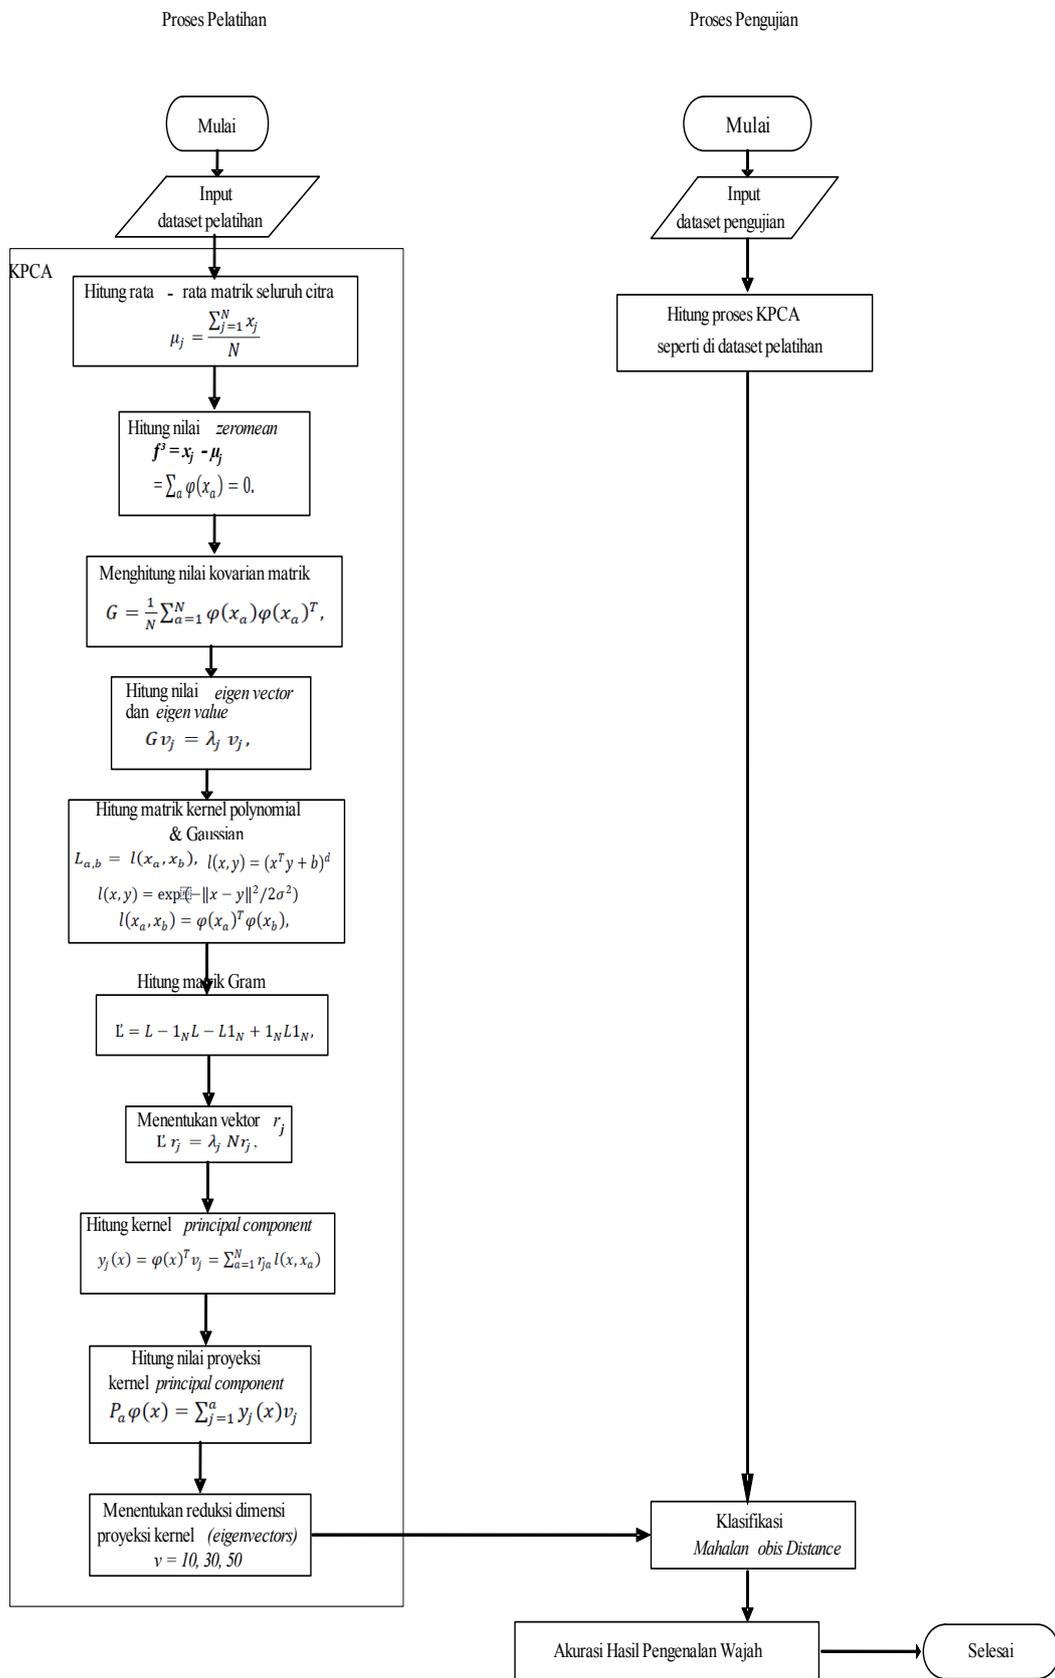
dan mensubstitusikan Persamaan 6 dengan $\varphi(x_e)^T$ sehingga didapatkan Persamaan 8:

$$\frac{1}{N} \sum_{\alpha=1}^N l(x_e, x_{\alpha}) \sum_{b=1}^N r_{jb} k(x_{\alpha}, x_b) = \lambda_j \sum_{\alpha=1}^N r_{j\alpha} k(x_e, x_{\alpha}), \tag{8}$$

atau notasi matrik seperti ditunjukkan pada Persamaan 9 dan 10:

$$L^2 r_j = \lambda_j N L r_j, \tag{9}$$

$$\text{dengan } L_{\alpha,b} = l(x_{\alpha}, x_b). \tag{10}$$



Gambar 1. Diagram alir rancangan sistem pengenalan citra wajah

dan r_j adalah N dimensi dari vektor kolom (r_{aj}). r_j dapat diselesaikan seperti ditunjukkan pada Persamaan 11:

$$L r_j = \lambda_j N r_j \quad (11)$$

sehingga menghasilkan kernel *principal components* seperti ditunjukkan pada Persamaan 12:

$$y_j(x) = \varphi(x)^T v_j = \sum_{a=1}^N r_{ja} l(x, x_a) \quad (12)$$

Jika proyeksi *dataset* $\{\varphi(x_a)\}$ tidak mempunyai *zero mean*, maka menggunakan matrik *Gram*, untuk mensubstitusikan matrik kernel L . Matrik *Gram* ditunjukkan pada Persamaan 13:

$$L = L - \mathbf{1}_N L - L \mathbf{1}_N + \mathbf{1}_N L \mathbf{1}_N, \quad (13)$$

dengan L adalah matrik $N \times N$ pada semua elemen sampai $1/N$.

Kekuatan metode kernel, secara eksplisit tidak harus untuk menghitung $\varphi(x_a)$. Terdapat beberapa jenis kernel yang sering digunakan, seperti kernel polynomial, kernel Gaussian, dan kernel RBF. Namun, pada penelitian ini menggunakan kernel polynomial (Persamaan 14) dengan konstanta $d=5$ dan kernel Gaussian dengan $2\sigma^2 = 3 \times 10^5$ (Persamaan 15):

$$l(x, y) = (x^T y)^d \quad (14)$$

$$l(x, y) = \exp(-\|x - y\|^2 / 2\sigma^2) \quad (15)$$

Selanjutnya menghitung nilai proyeksi kernel *principal component* menggunakan Persamaan 16:

$$P_a \varphi(x) = \sum_{j=1}^a y_j(x) v_j \quad (16)$$

dengan v_j adalah *eigenvectors*. Jika a cukup besar, maka $P_a \varphi(x) \approx \varphi(x)$. Karena menentukan pra citra x secara tepat kesulitan, maka diasumsikan suatu pendekatan z seperti ditunjukkan pada Persamaan 17:

$$\varphi(z) \approx P_a \varphi(x). \quad (17)$$

Hal ini dapat didekati dengan minimalisasi seperti ditunjukkan pada Persamaan 18:

$$\delta(z) = \|\varphi(z) - P_a \varphi(x)\|^2. \quad (18)$$

Langkah berikutnya adalah melakukan reduksi dimensi proyeksi kernel secara signifikan (mampu mencakup 99% variasi statistik) berdasarkan Persamaan 19 [8]:

$$\sum_{j=1}^t \lambda_j / \sum_{j=1}^a \lambda_j \geq 0.99. \quad (19)$$

Euclidean Distance

Setelah menentukan reduksi dimensi proyeksi kernel *PCA*, langkah selanjutnya adalah melakukan klasifikasi. Pada penelitian ini menggunakan *Euclidean Distance*, seperti ditunjukkan pada Persamaan 20 [10]:

$$d(x_a, x_b) = \sqrt{\sum_{j=1}^t (x_{aj} - x_{bj})^2} \quad (20)$$

dengan x_a adalah nilai proyeksi kernel *principal component* dari citra pelatihan dan x_b adalah nilai proyeksi kernel *principal component* dari citra pengujian. j menunjukkan nilai terbesar dan t menunjukkan nilai reduksi dimensi yang ditentukan.

Secara ringkas, langkah – langkah pengenalan citra wajah menggunakan *KPCA* dan *Euclidean Distance* adalah sebagai berikut:

1. Membangun matrik kernel L dari *dataset* pelatihan $\{x_a\}$ menggunakan Persamaan 10.
2. Menghitung matrik *Gram* L menggunakan Persamaan 13.
3. Menggunakan Persamaan 11 untuk menghitung vektor r_j (substitusikan L dengan L).
4. Menghitung kernel *principal component* $y_j(x)$ menggunakan Persamaan 12, 14 dan 15.
5. Menghitung nilai proyeksi kernel *principal component* menggunakan Persamaan 16 dan Persamaan 18.
6. Melakukan reduksi dimensi proyeksi kernel (*eigenvectors*) setelah mengurutkan *eigenvalues* secara *descending*. Pada penelitian ini menentukan $v = 25$ dan 50 dari nilai *eigenvalues* terbesarnya.
7. Melakukan klasifikasi menggunakan *Euclidean Distance* menggunakan Persamaan 20.

HASIL DAN PEMBAHASAN

Pada penelitian ini menggunakan tiga buah basis data yaitu ORL, YALE, dan BERN. Pertama, basis data ORL terdiri dari 40 orang dan masing-masing orang memiliki 10 pose, sehingga jumlah keseluruhan sebanyak 400 data dengan ukuran citra 92x112. Kedua, basis data YALE terdiri dari 15 orang, masing-masing orang memiliki 11 pose, sehingga data total ada 165 data dengan ukuran citra 64x88. Dan ketiga, basis data BERN

terdiri dari 28 orang yang memiliki 10 pose per orang dengan ukuran citra 64x88. Ketiga basis data ini sudah dinormalisasi dengan intensitas warna *greyscale*.

Skenario ujicoba pada penelitian ini dilakukan secara acak, masing-masing skenario terdiri dari tiga macam variasi yaitu menggunakan 3, 5 dan 7 data pelatihan untuk setiap kelas, kemudian sisa data setiap kelas tersebut digunakan sebagai data pengujian.

Tabel 1, Tabel 2 dan Tabel 3 menunjukkan hasil ujicoba dari sistem yang dibuat dengan data terurut menggunakan basis data ORL, YALE dan BERN dimana prosentase yang ditulis pada tabel adalah prosentase tertinggi dari data acak.

Berdasarkan Tabel 1, Tabel 2 dan Tabel 3, dengan meningkatnya jumlah data yang digunakan untuk proses pelatihan maka hasil akurasi pengenalannya lebih tinggi. Prosentase pengenalan citra wajah tertinggi sebesar 98.50% yaitu pada basis data ORL dengan menggunakan kernel Gaussian dan reduksi dimensi $v = 50$. Hal ini terjadi karena pada basis data ORL perbedaan tiap-tiap pose wajah sangat tipis sehingga fitur yang dimiliki hampir sama.

SIMPULAN

Kesimpulan yang diperoleh setelah melakukan ujicoba dan evaluasi terhadap sistem pengenalan wajah menggunakan *Kernel Principal Component Analysis*

Tabel 1. Akurasi pengenalan citra wajah ORL

Skenario (jumlah data pelatihan)	Kernel polynomial (*)	Kernel polynomial (**)	Kernel Gaussian (***)	Kernel Gaussian (****)
3	92,86%	93,16%	95,46%	96,25%
5	93,35%	93,64%	96,14%	96,85%
7	93,54%	94,92%	97,74%	98,50%

Keterangan untuk semua tabel hasil ujicoba:

* : $d = 5, v = 25$; ** : $d = 5, v = 50$

*** : $2\sigma^2 = 3 \times 10^5, v = 25$; ****: $2\sigma^2 = 3 \times 10^5, v = 50$

Tabel 2. Akurasi pengenalan citra wajah YALE

Skenario (jumlah data pelatihan)	Kernel polynomial (*)	Kernel polynomial (**)	Kernel Gaussian (***)	Kernel Gaussian (****)
3	91,45%	92,15%	95,25%	95,75%
5	91,75%	93,65%	95,95%	96,45%
7	92,95%	94,85%	96,90%	97,65%

Tabel 3. Akurasi pengenalan citra wajah BERN

Skenario (jumlah data pelatihan)	Kernel polynomial (*)	Kernel polynomial (**)	Kernel Gaussian (***)	Kernel Gaussian (****)
3	92,27%	93,26%	96,45%	96,25%
5	92,51%	93,84%	96,87%	96,55%
7	93,89%	95,32%	97,24%	97,95%

dan *Euclidean Distance* pada basis data citra wajah ORL, YALE dan BERN adalah sebagai berikut:

1. Semakin banyak data pelatihan yang digunakan maka prosentase akurasi pengenalan semakin tinggi pula.
2. Penggunaan kernel Gaussian menghasilkan prosentase akurasi pengenalan yang lebih tinggi dibandingkan dengan penggunaan kernel polynomial.
3. Hasil akurasi pengenalan tertinggi yaitu sebesar 98,50% pada basis data citra wajah ORL.

DAFTAR PUSTAKA

- [1] Turk, M.A., Pentland, A.P., 1991. Eigenfaces for recognition. *Journal of Cognitive Neuroscience* 3 (1), 71–86.
- [2] Belhumeur, J.H.P.N., Kriegman, D., 1997. Eigenfaces vs. fisherfaces: Recognition using class specific linear projection, *IEEE Transaction on Pattern Analysis of Machine Intelligent* 19 (7), 711–720.
- [3] Scholkopf, B., Smola, A., Muller, K.R., 1998. Nonlinear component analysis as a kernel eigenvalue problem. *Neural Computing* 10(5), 1299–1319.
- [4] Djakaria, I., Guritno, S., Kartiko, H.S., 2010. Visualisasi data iris menggunakan Analisis Komponen Utama dan Analisis Komponen Utama Kernel, *Jurnal ILMU DASAR* 11 (1), 31–38.
- [5] Wen, Y., He, L., Shi, P., 2012. Face recognition using difference vector plus KPCA, *Digital Signal Processing* 22 (7), 140–146.
- [6] López, M.M., Ramírez, J., Górriz, J.M., Álvarez, I., Salas-Gonzalez, D., Segovia, F., Chaves, R., 2009. SVM-based CAD system for early detection of the Alzheimer's disease using kernel PCA and LDA, *Neuroscience Letters* 464 (3), 233–238.
- [7] Zhang, R., Wang, W., Mac, Y., 2010. Approximations of the standard Principal Components Analysis and kernel PCA. *Expert Systems with Applications* 37 (9), 6531–6537.
- [8] Sahbi, H., 2007. Kernel PCA for similarity invariant shape recognition. *Neurocomputing* 70 (16-18), 3034–3045.
- [9] Ekstrom, J., 2011. Euclidean Distance beyond normal distributions. Website: <http://statistics.ucla.edu/system/resources.pdf>, diakses tanggal 30 Mei 2011.
- [10] Ommy, R., Rizal, A., dan Murti, M.A., 2008. Pengenalan identitas manusia melalui pola iris mata menggunakan Transformasi Wavelet dan Euclidean Distance. *Konferensi Nasional Sistem dan Informatika*, KNS&I08-056, Bali, 15 Nopember, 316–320.
- [11] Wang, Q., 2011. Kernel principal component analysis and its applications in face recognition and active shape models. Website: <http://arxiv.org/pdf/1207.3538>, diakses tanggal 1 April 2011.