

**UNJUK KERJA METODE KLASIFIKASI SUPPORT VECTOR MACHINE (SVM) DENGAN LEARNING VECTOR QUANTIZATION (LVQ) PADA APLIKASI PENGENALAN WAJAH**

Yustina Retno Wahyu Utami<sup>1)</sup>, Teguh Susyanto<sup>2)</sup>.

**Abstract**

*Face recognition techniques and classification methods have been proposed, but not many techniques that compare performance between methods. This research wants to analyze the performance of recognition. The method which are studied and compared are support vector machine and learning vector quantization. The result showed that the performance of the method, on the varied training number, LVQ method is better than SVM. In large number of classes, LVQ method is better than SVW.*

*Keywords: classification, face recognition, LVQ, SVM*

**I. PENDAHULUAN**

Seiring dengan perkembangan teknologi informasi, kemajuan dibidang pemograman juga mengalami peningkatan kerumitan dan fungsi. Salah satu bidang yang sedang berkembang yaitu biometris. Bidang tersebut memproses ciri-ciri khusus fisik seseorang yang dapat digunakan sebagai sistem pengidentifikasian dan keamanan.

Meningkatnya kekhawatiran masyarakat terhadap berbagai macam ancaman dan semakin lemahnya sistem keamanan dengan menggunakan inputan password yang berupa string atau karakter telah melahirkan cara baru untuk melindungi software, hardware, bahkan gedung dari serangan pihak luar, maka salah satu cara yang digunakan untuk mengatasi permasalahan tersebut yaitu sistem biometris. Contoh biometris adalah *finger recognition*, *voice regonition*, *iris recognition*, *face recognition* dan lain-lain.

Karakteristik fisiologis yang akan dipilih sebagai subjek kali ini yaitu *face recognition* pengidentifikasian melalui pola wajah, karena pola wajah memenuhi beberapa persyaratan untuk digunakan sebagai

---

<sup>1,2)</sup> Program Studi Teknik Informatika, STMIK Sinar Nusantara Surakarta

indikator karakteristik biometrik dalam identifikasi personal yaitu karakteristik tersebut dimiliki oleh semua orang (universal), bersifat unik, karakteristik tersebut tidak dapat diubah (permanen) dan karakteristik tersebut diambil atau diukur secara kualitatif.

Sampai saat ini pola wajah masih memegang peranan penting bagi berbagai pihak yang membutuhkan identifikasi personal dengan menggunakan indikator karakteristik fisiologi manusia. Secara umum pola wajah digunakan sebagai sistem identifikasi yang dapat digunakan dalam aplikasi teknologi seperti:

- *Access system security*, yaitu akses untuk masuk suatu area atau ruangan tertentu,
- *Restricted dan Authentication system*, yaitu akses data yang sifatnya rahasia dan terbatas misalnya pada perbankan dan diplomatik.
- Teknologi untuk memproses gambar yang telah dikenal antara lain teknologi *computer vision* dan *image processing* yang memungkinkan komputer dapat mengenali suatu gambar (citra) digital.
- Teknologi *face recognition* adalah suatu proses perhitungan yang dilakukan oleh komputer dengan tujuan agar komputer dapat mengenali wajah seseorang. Teknologi *face recognition* dapat digunakan untuk mempercepat proses pencarian informasi berdasarkan foto atau image wajah seseorang, dengan catatan data yang dicari harus terlebih dahulu di inputkan kedalam database komputer.

Agar aplikasi dapat mengenali suatu wajah, harus dipersiapkan database yang berisi informasi sejumlah citra wajah yang telah diidentifikasi terlebih dahulu. Database ini diperlukan untuk menyimpan bagian-bagian penting dari wajah yang disebut *eigenfaces*.

Terdapat beberapa masalah yang harus diselesaikan dalam penelitian ini. Masalah ini bisa dibagi dalam beberapa bagian sebagai berikut :

- Bagaimana algoritma *Principal Component Analysis* (PCA) dan *Linear Discriminant Analysis* (LDA) untuk ekstraksi ciri citra wajah?
- Bagaimana mengklasifikasikan feature metode *Support Vector Machine* (SVM) dan *Learning Vector Quantization* (LVQ)?

- Bagaimana unjuk kerja metode klasifikasi *Support Vector Machine* (SVM) dan *Learning Vector Quantization* (LVQ)?

Adapun maksud dan tujuan penelitian ini, adalah :

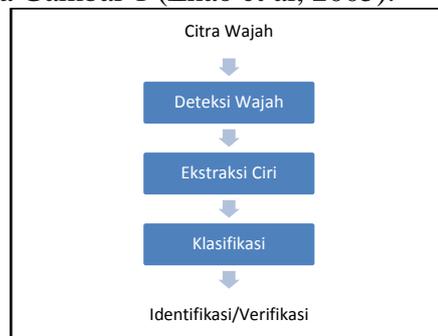
- Merancang-bangun prototype aplikasi pengenalan wajah
- Membandingkan dan menganalisis unjuk kerja metode SVM dengan LVQ

## II. KAJIAN PUSTAKA

### 2.1 Pengenalan Wajah

Telah banyak usaha yang dilakukan oleh para peneliti untuk membangun suatu sistem berbasis pengenalan wajah dengan menggunakan berbagai metode yang berbeda-beda meliputi pemilihan ekstraksi ciri dan teknik klasifikasi. Walaupun sudah banyak teknik-teknik pengenalan wajah telah dikemukakan dan telah menunjukkan hasil yang signifikan, namun pengenalan wajah yang handal masih sukar didapatkan (Paul and Michael, 2004, Zhao et al, 2005).

Studi awal pengenalan wajah telah dilakukan dengan suatu pendekatan sederhana. Pada sistem pengenalan wajah yang akan dikembangkan menggunakan metode gabungan PCA dan LDA. Secara umum diagram blok sistem pengenalan wajah sebagaimana ditunjukkan pada Gambar 1 (Zhao et al, 2005).



Gambar 1 Diagram blok Sistem pengenalan Wajah

Pada Gambar 1, ditunjukkan bahwa sistem pengenalan wajah meliputi 3 bagian yaitu:

1. Deteksi dan normalisasi wajah secara kasar
2. Ekstraksi ciri dan normalisasi wajah secara akurat
3. Klasifikasi untuk mendapatkan hasil identifikasi atau verifikasi

## 2.2 *Principal Component Analysis (PCA)*

*Principal Component Analysis* (PCA) adalah teknik reduksi dimensi yang umum digunakan pada aplikasi pemrosesan citra. Prinsip dasar dari algoritma PCA adalah menentukan komponen-komponen atau dimensi-dimensi dari semua citra mempunyai distribusi energi maksimal pada komponen-komponen tersebut. Maka dimensi-dimensi yang berkontribusi tersebutlah yang dipertahankan untuk tahap pemrosesan selanjutnya dan sisanya disingkirkan.

Prinsip das/ar dari algoritma PCA adalah memproyeksikan image ke dalam bidang ruang eigen-nya. Caranya adalah dengan mencari eigen vector yang dimiliki setiap image dan memproyeksikannya ke dalam ruang eigen yang didapat tersebut. Besarnya dimensi ruang eigen tergantung dari jumlah image yang dimiliki oleh program training.

## 2.3 *Linear Discriminant Analysis (LDA)*

Seperti pada PCA, algoritma LDA memiliki karakteristik perhitungan matriks yang sama dengan PCA, perbedaan dasarnya adalah pada LDA diusahakan adanya perbedaan yang maksimum antar kelas yang berbeda (kelas adalah kumpulan citra dari orang yang sama) dan perbedaan yang minimum dari citra dalam kelas.

LDA bekerja berdasarkan analisa matrik penyebaran (*scatter matrix analysis*) yang bertujuan menemukan suatu proyeksi optimal sehingga dapat memproyeksikan data input pada ruang dengan dimensi yang lebih kecil dimana semua pola (pattern) dapat dipisahkan semaksimal mungkin. Karenanya untuk tujuan pemisahan tersebut maka LDA akan mencoba untuk memaksimalkan penyebaran data-data input diantara kelas-kelas yang berbeda dan sekaligus juga meminimalkan penyebaran input pada kelas yang sama. Perbedaan antar kelas direpresentasikan oleh matriks  $S_b$  (*scatter between class*) dan perbedaan dalam kelas direpresentasikan oleh matriks  $S_w$  (*scatter within class*).

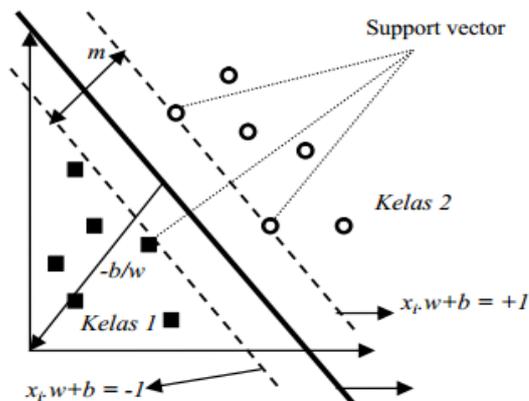
## 2.4 *Support Vector Machine (SVM)*

*Support Vector Machine* (SVM) adalah suatu metode yang berusaha menemukan hyperplane yang terbaik pada input *space*. Prinsip dasar SVM adalah linear classifier yang selanjutnya dikembangkan agar dapat bekerja pada problem non-linear dengan

memasukkan konsep kernel trick pada ruang kerja berdimensi tinggi (Nugroho, dkk, 2013). SVM dapat melakukan klasifikasi data yang terpisah secara linier (*linearly separable*) dan non-linier (*nonlinear separable*) (Burges, 1998). *Linearly separable* data merupakan data yang dapat dipisahkan secara linier. Misalkan  $\{x_1, \dots, x_n\}$  adalah dataset dan di  $x_i \in \mathbb{R}^d$ , serta  $y_i \in \{+1, -1\}$  adalah label kelas dari data  $x_i$ . Anggap ada beberapa hyperplane yang memisahkan sampel positif dan negatif, maka  $x$  yang berada pada hyperplane akan memenuhi persamaan  $w \cdot x + b = 0$ . Untuk permasalahan data linier, algoritma *support vector* hanya mencari hyperplane dengan margin yang terbesar (jarak antara dua kelas pola). Hard margin hyperplane ditunjukkan pada Gambar 2. Hyperplane terbaik tidak hanya dapat memisahkan data dengan baik tetapi juga yang memiliki margin paling besar. Data yang berada pada bidang pembatas ini disebut support vector.

Untuk menyelesaikan permasalahan data non-linier dalam SVM adalah dengan cara memetakan data ke ruang dimensi lebih tinggi (ruang fitur atau *feature space*) (Burges, 1998), dimana data pada ruang tersebut dapat dipisahkan secara linier, dengan menggunakan transformasi  $\Phi$ .

$$\Phi: \mathbb{R}^d \rightarrow H$$



Gambar 2. Hard Margin Hyperplane

Dengan demikian algoritma pelatihan tergantung dari data melalui dot product dalam  $H$ . Sebagai contoh  $\Phi(x_i) \cdot \Phi(x_j)$ . Jika terdapat fungsi kernel  $K$ , sedemikian hingga  $K(x_i, x_j) = \Phi(x_i) \cdot \Phi(x_j)$ , maka algoritma pelatihan hanya memerlukan fungsi kernel  $K$ , tanpa harus mengetahui transformasi  $\Phi$  secara pasti.

SVM pertama kali dikembangkan oleh Vapniks untuk klasifikasi biner, namun selanjutnya dikembangkan untuk klasifikasi multiclass (banyak kelas). Pendekatannya adalah dengan membangun multiclass classifier, yaitu dengan cara menggabungkan beberapa SVM biner. Pendekatan ini terdiri dari metode satu lawan semua (*One Against All*) dan metode satu lawan satu (*One Against One*) (Hsu and Lin, 2002).

## 2.5 Learning Vector Quantization (LVQ)

*Learning Vector Quantization* merupakan metode klasifikasi jaringan saraf tiruan. Algoritma pembelajaran LVQ adalah sebagai berikut (Fauset 1994):

x: vector pelatihan ( $x_1, \dots, x_i, \dots, x_n$ )

T: klas atau kategori vector pembelajaran

$w_j$ : vector bobot unit output

$C_j$ : kategori/klas yang diberikan oleh unit output j

$|x-w_j|$ : jarak euclidian antara vector input dan vector output

L0 : Inisialisasi vector referensi

Inisialisasi laju pembelajaran  $\alpha(0)$

L1 : Selama syarat berhenti false kerjakan langkah 2-6

L2: Untuk setiap vector input pembelajaran x, kerjakan langkah 3-4

L3: Cari j sehingga  $|x-w_j|$  minimum

L4: Perbaharui  $w_j$

Bila  $T=C_j$ , maka

$$w_j(\text{baru}) = w_j(\text{lama}) + \alpha \cdot |x-w_j(\text{lama})|$$

Bila  $T \neq C_j$ , maka

$$w_j(\text{baru}) = w_j(\text{lama}) - \alpha \cdot |x-w_j(\text{lama})|$$

L5 : Kurangi laju pembelajaran

L6 : Uji syarat berhenti;

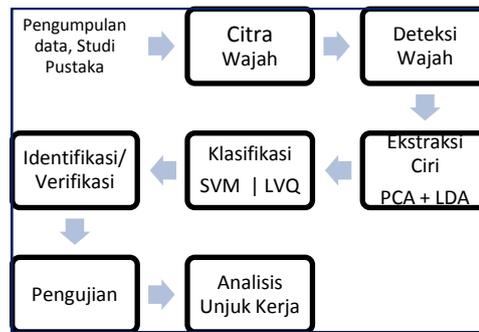
Syarat berhenti : spesifikasi cacah iterasi atau laju pembelajaran mencapai nilai yang cukup kecil.

Metode LVQ telah digunakan untuk verifikasi wajah (Fadlil dan Yeki, 2010) dan menghasilkan unjuk kerja yang baik.

## III. METODE PENELITIAN

### 3.1 Kerangka penelitian

Penelitian dilaksanakan selama kurang lebih 8 (delapan) bulan. Kerangka penelitian disajikan dalam Gambar 3.



Gambar 3. Kerangka Penelitian

Tahapan penelitian yang tersaji dalam gambar 3 adalah sebagai berikut:

- Pengumpulan data dan studi pustaka. Hal ini dilakukan untuk mempelajari karakteristik metode/algorithm yang digunakan dalam prototype aplikasi pengenalan wajah
- Citra wajah diambil dari database wajah yang sudah ada, database standar dalam penelitian-penelitian.
- Citra wajah diekstraksi ciri dengan metode gabungan PCA+LDA. Metode gabungan ini dapat mereduksi ukuran ciri (Purwanto,2008)
- Ciri citra kemudian diklasifikasikan dengan metode SVM dan kemudian LVQ.
- Hasil Klasifikasi kemudian diidentifikasi apakah citra wajah terklasifikasi dengan benar atau tidak.

### 3.2 Sumber Data

#### 1) Data primer

Data wajah yang digunakan berupa basis data wajah yang sudah ada (standar penelitian) yakni dari YaleB, atau Cambridge, atau Columbia university.

#### 2) Data sekunder

Data sekunder diperoleh dari luar obyek penelitian yang masih ada hubungannya dengan masalah yang diteliti dan dari literatur. Data sekunder yang diperlukan meliputi referensi baik dari buku, jurnal dan media elektronik.

### 3.3 Metode Pengukuran Unjuk Kerja

Unjuk kerja diukur dengan membandingkan banyaknya citra yang terklasifikasi benar dengan banyaknya pengujian.

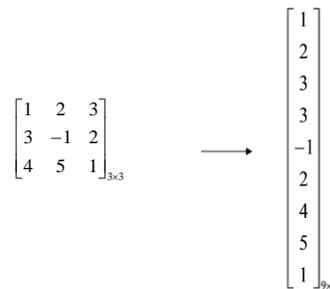
## IV. HASIL DAN PEMBAHASAN

### 4.1 Perancangan

#### A. Ekstraksi citra wajah dengan Algoritma PCA + LDA

Tujuan dari ekstraksi citra wajah atau fase *training* adalah untuk mendapatkan fitur-fitur utama citra wajah, yang disebut *eigenface*, yang nantinya akan digunakan untuk dibandingkan dengan citra wajah yang akan di deteksi. Tahap-tahap ekstraksi citra atau fase *training* menggunakan algoritma *Principal Component Analysis* (PCA) adalah sebagai berikut:

1. Setiap citra wajah yang di-*training* dikonversikan ke dalam sebuah vektor baris. Seperti pada Gambar 4, matriks  $a \times b$  dikonversikan ke dalam sebuah vektor kolom  $\vec{x}$  dengan ukuran  $ab \times 1$ .



Gambar 4. Gambaran baris vektor dari citra wajah 2-dimensi

2. Bila terdapat citra sejumlah  $n$  buah, maka akan didapat vektor baris  $ab$  sebanyak  $n$ . Semua vektor baris tersebut digabung menjadi sebuah matrik, dengan ukuran  $ab \times n$ .

$$S = [\vec{x}_1 \ \vec{x}_2 \ \vec{x}_3 \ \dots \ \vec{x}_n] \quad (1)$$

3. Hitung rata-rata vektor citra wajah  $\mu$  dari  $n$  vektor baris :

$$\mu = \frac{\sum_{i=1}^n \vec{x}_i}{n} \quad (2)$$

4. Hitung matrik  $\Phi$ , diperoleh dari matrik hasil tahap 2 dikurangi rata-rata vektor citra wajah  $\mu$  sebagai berikut:

$$\Phi_i = \vec{x}_i - \mu \quad (3)$$

Matrik  $\Phi$  yang diperoleh mempunyai ukuran  $ab \times n$ .

5. Hitung matrik *Covariance*  $C$ , yang diperoleh dari perkalian matrik  $\Phi$  dengan transposenya  $\Phi^T$ , sebagai berikut:
- $$C = \Phi^T \times \Phi \quad (4)$$

dengan matrik  $\Phi$  mempunyai ukuran  $ab \times n$  dan matrik  $\Phi^T$  berukuran  $n \times ab$ , sehingga diperoleh matrik *covariance* berukuran  $n \times n$ .

6. Langkah berikutnya adalah mencari *eigenvalue* dan *eigenvector* dari matrik *covariance*  $C$ . Perolehan *eigenvalue* dan *eigenvector* yang dapat dianggap mewakili seluruh distribusi data, dalam penelitian ini digunakan fungsi  **eig** dari Matlab. Citra wajah yang di-training, diperoleh beberapa *eigenvalue*. Kemudian dari *eigenvalue* tersebut, dipilih beberapa nilai yang tertinggi. Proses selanjutnya adalah melakukan proses pengurutan *eigenvector*  $V_{PCA}$  yang berkorelasi dengan *eigenvalue* dari nilai terbesar sampai terkecil.
7. Selanjutnya matriks ciri PCA diperoleh dari perkalian  $V_{PCA}$  dengan  $\Phi$ .

$$U = V_{PCA} \times \Phi \quad (5)$$

8. Matrik  $U$  berisi citra semua kelas. Bila  $X_1, X_2, \dots, X_c$  adalah kelas wajah pada matriks  $U$  di mana setiap kelas  $X_i$  terdapat  $k$  citra wajah, dapat dihitung rata-rata citra  $\mu_i$  untuk setiap kelas  $X_i$  adalah:

$$\mu_i = \frac{1}{k} \sum_{j=1}^k x_j \quad (6)$$

9. Hitung rata-rata citra  $\mu$  dari semua class di matriks  $U$  sebagai berikut:

$$\mu_U = \frac{1}{c} \sum_{i=1}^c \mu_i \quad (7)$$

10. Hitung within-class scatter matrix :

$$S_W = \sum_{i=1}^c \sum_{x_k \in X_i} (x_k - \mu_i)(x_k - \mu_i)^T \quad (8)$$

11. Hitung between-class scatter matrix:

$$S_B = \sum_{i=1}^c N_i (\mu_i - \mu_U)(\mu_i - \mu_U)^T \quad (9)$$

12. Cari eigenvalue dan eigenvector dari  $S_W$  dan  $S_B$  yang disebut  $V_{LDA}$ . (10)

13. Matrik  $U$  dikurangi rata-rata seluruh citra.

$$R = U - \mu_U \quad (11)$$

14. Matrik ciri diperoleh dari perkalian dari matriks  $R$  dengan eigenvector  $V_{LDA}$ :

$$f_{LDA} = V_{LDA} \times R \quad (12)$$

### B. Deteksi Wajah dengan Algoritma PCA + LDA

1. Wajah yang akan dideteksi  $I$  terlebih dahulu diekstrak untuk mendapatkan fitur-fitur utamanya, kemudian diproyeksikan ke ruang citra wajah hasil *training* dengan rumus (13):

$$\omega_i = U_i^T \times (I - \mu) \quad (13) \quad i = 1, 2, \dots, k$$

dimana  $U$  adalah matrik *eigenface* wajah hasil *training*, dan  $\mu$  adalah rata-rata vektor baris citra wajah yang di-*training*.

Nilai yang dihasilkan  $\omega_i$  mewakili wajah yang dideteksi dan disimpan dalam vektor  $Z$ .

$$Z = [\omega_1 \ \omega_2 \ \omega_3 \ \dots \ \omega_k] \quad (14)$$

2. Selanjutnya  $Z$  dikurangi dengan  $\mu_U$  yakni rata-rata matriks  $U$ .

$$Y = Z - \mu_U \quad (15)$$

3. Matrik  $Y$  dikalikan dengan eigenvector  $V_{LDA}$ .

$$f = Y \times V_{LDA} \quad (16)$$

4. Matrik  $f$  ini kemudian dikelaskan dengan metode klasifikasi SVM dan LVQ.

## 4.2 Implementasi

Tahapan implementasi meliputi pembuatan fungsi PCA, fungsi LDA, klasifikasi dengan SVM, pembuatan training untuk LVQ, klasifikasi dengan LVQ. Implementasi program menggunakan perangkat lunak matlab.

### A. Ekstraksi Ciri

1) Mengubah citra dimensi 2 menjadi vektor baris

$$I = \text{OneD}(i);$$

2) Fungsi PCA

Fungsi untuk mencari matriks ciri dari citra training menggunakan algoritma PCA adalah sebagai berikut.

```
[VPca,DPca,fPca,g,rerataPCA, training, Q]=PCA(faces,group, 8,10);
```

### 3) Fungsi LDA

Fungsi untuk memperoleh matriks ciri hasil fungsi PCA menggunakan algoritma LDA adalah sebagai berikut.

```
[VLda, DLda, fLda, rerataLDA] =LDA(fPca,train,kelas);
```

## B. Deteksi wajah

- 1) Bila terdapat wajah yang akan diklasifikasikan, ubah citra menjadi vektor baris

```
J=OneD(i);
```

- 2) Cari ciri dari matriks J

```
[f,fl]=ekstraksi(J,rerataPCA, rerataLDA, VPca, VLda )
```

- 3) Klasifikasi menggunakan *Support Vector Machine* (SVM)

Setelah diperoleh matriks ciri citra training dan citra uji menggunakan algoritma PCA + LDA, citra tersebut diklasifikasi dengan metode klasifikasi SVM. Fungsi SVM menggunakan fungsi yang telah tersedia di matlab. Pemanggilan fungsi klasifikasi dengan SVM adalah sebagai berikut.

```
kelas=multisvm(fLda,g,fl)
```

- 4) Klasifikasi menggunakan *Learning Vector Quantization* (LVQ)

Klasifikasi dengan metode LVQ menggunakan fungsi yang telah tersedia di matlab. Penggunaan metode klasifikasi LVQ didahului dengan membuat training dari LVQ.

- Membuat training set LVQ

```
function net=lvqclaasify(fLda,g,w)
    fl=fLda';
    t=ind2vec(str2num(char(g))');
    net=newlvq(fl,20,w);
    net.trainParam.epochs=100;
    net=train(net,fl,t);
end
```

- Klasifikasi LVQ

```
Y=sim(net,double(f));
Yc=vec2ind(Y);
```

### C. Implementasi Antarmuka Pengguna

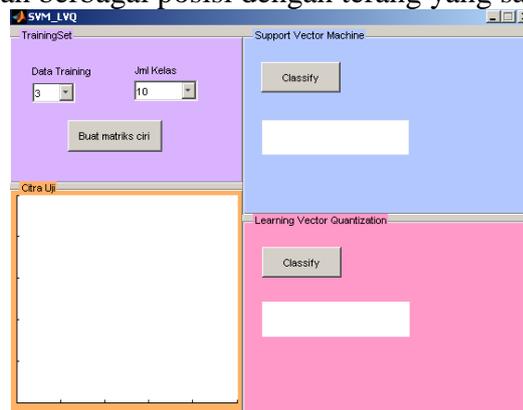
Hasil implementasi antarmuka pengguna adalah seperti Gambar 5.

#### 4.3 Pengujian

Unjuk kerja dalam penelitian ini diukur melalui perbandingan berapa citra yang terklasifikasi benar dengan banyaknya pengujian yang dilakukan. Pengujian yang dilakukan bertujuan untuk mengetahui:

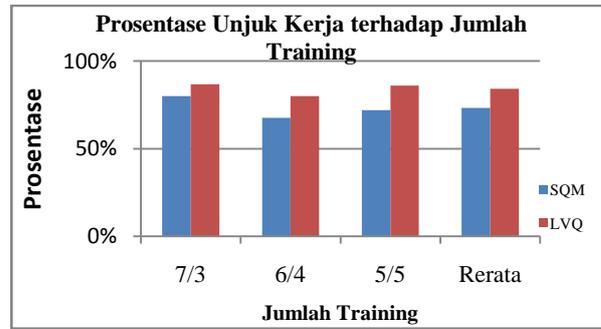
1. pengaruh banyaknya citra training terhadap unjuk kerja SVM dan LVQ
2. pengaruh banyaknya kelas terhadap unjuk kerja tiap metode.

Citra yang digunakan dalam pengujian diambil dari basis data citra standar untuk aplikasi pengenalan wajah. Citra diunduh dari basis data AT&T yang berukuran 112 x 92 piksel. Citra berisi wajah dengan berbagai posisi dengan terang yang sama.



Gambar 5. Antarmuka Pengguna Prototipe Pengenalan Wajah

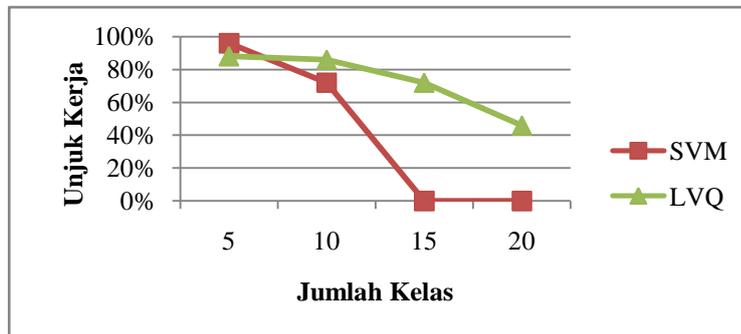
Pengujian pertama dilakukan dengan mengambil 10 kelas wajah dengan jumlah sampel 10 citra untuk tiap wajah. Pengujian pada 7 citra training dan 3 citra uji diperoleh metode klasifikasi SVM memiliki unjuk kerja 80% dan metode LVQ 87%. Pengujian dengan 6 citra training dan 4 citra uji diperoleh bahwa unjuk kerja SVM 68% dan LVQ 80%. Pengujian dengan 5 citra uji dan 5 citra training diperoleh bahwa unjuk kerja SVM sebesar 72% dan LVQ 86%.



Gambar 6. Prosentase Unjuk Kerja terhadap Jumlah Data Training

Berdasarkan pengujian terhadap 100 sampel dari 10 kelas wajah diperoleh bahwa unjuk kerja klasifikasi dengan metode *Learning Vector Quantization* (LVQ) lebih baik dari metode *Support Vector Machine* (SVM).

Pengujian kedua menggunakan 5 citra training dan 5 citra uji. Pengujian dilakukan pada jumlah kelas yang berbeda yaitu 5, 10, 15, dan 20 kelas. Hasil pengujian disajikan dalam Gambar 7.



Gambar 7. Unjuk Kerja Metode terhadap Jumlah Kelas

Berdasarkan pengujian terhadap banyaknya kelas, metode SVM menunjukkan unjuk kerja lebih dari 95% pada jumlah kelas yang kecil, namun pada kelas yang besar metode ini memiliki unjuk kerja lebih rendah dari LVQ. Sedangkan metode LVQ dengan semakin bertambahnya jumlah kelas memiliki unjuk kerja yang lebih baik dari SVM.

## V. KESIMPULAN

Kesimpulan dari penelitian yang dilakukan sampai saat ini adalah:

- Pengenalan wajah dapat dilakukan dengan yang menggabungkan algoritma PCA dan LDA untuk ekstraksi ciri, dan sebagai metode klasifikasinya menggunakan metode *Support Vector Machine* (SVM) dan *Learning Vector Quantization* (LVQ).
- Berdasarkan pengujian terhadap 100 sampel wajah diperoleh bahwa unjuk kerja metode *Learning Vector Quantization* (LVQ) 11% lebih baik dari *Support Vector Machine* (SVM).
- Pengujian terhadap banyaknya kelas, SVM memiliki unjuk kerja 8% lebih baik dari LVQ pada 5 kelas, dan LVQ 42% lebih baik dari SVM pada 15 kelas.

## DAFTAR PUSTAKA

- Burges JC, 1998, *A Tutorial on Support Vector Machines for Pattern Recognition*, *Data Mining and Knowledge Discovery*, 2: 955-974.
- Fadlil, Abdul dan Yeki, Surya, 2010, Sistem Verifikasi Wajah Menggunakan Jaringan Syaraf Tiruan *Learning Vector Quantization*, *Jurnal Informatika*, Vol. 4, No. 2
- Hsu CW and Lin CJ, 2002, *A Comparison of Methods for Multi-class Support Vector Machines*, *IEEE Transactions on Neural network*, 13: 415-425.
- Nugroho, Witarto dan Handoko, *Support Vector Machine : Teori dan Aplikasinya Dalam Bioinformatika*. Kuliah Umum Ilmu Komputer.com, URL: <http://www.ilmukomputer.com/antoSVM.pdf>, diakses tanggal 10 Desember 2013
- Purwanto, JE, 2008, Prototipe Pengenalan Wajah Melalui Webcam dengan menggunakan Algoritma *Principal Component Analysis* dan *Linier Discriminant Analysis* (LDA), *Tugas Akhir*, Universitas Komputer Indonesia.
- Zhao, W., Chellappa, R., Phillips, P. J., and Rosenfeld, A., 2005, *Face Recognition: A Literature survey*, *ACM Computing Surveys*, Vol. 35, No. 4, pp. 399-458.