

## PENGENALAN POLA SIDIK JARI DENGAN METODE *LOCAL BINARY PATTERN* DAN *LEARNING VECTOR QUANTIZATION*

Adnan Putra Rihi Pati<sup>1</sup>, Adriana Fanggidae<sup>2</sup>, Dony M. Sihotang<sup>3</sup>  
<sup>1,2,3</sup> Jurusan Ilmu Komputer, Fakultas Sains dan Teknik, Universitas Nusa Cendana  
Email : [putra.rp.reborn@gmail.com](mailto:putra.rp.reborn@gmail.com)<sup>1</sup>, [adrianafanggidae@staf.undana.ac.id](mailto:adrianafanggidae@staf.undana.ac.id)<sup>2</sup>,  
[donisihotang9@gmail.com](mailto:donisihotang9@gmail.com)<sup>3</sup>

### ABSTRAK

Sidik jari merupakan struktur genetika dalam bentuk pola yang sangat detail dan tanda yang melekat pada diri manusia. Banyak sistem biometrika yang menggunakan sidik jari sebagai data masukan, karena sifat dari sidik jari setiap individu berbeda meskipun kembar identik dan tidak berubah kecuali mendapat kecelakaan. Metode yang digunakan dalam penelitian ini yaitu segmentasi dengan algoritma *Otsu thresholding*, ekstraksi ciri dengan algoritma *Local Binary Pattern* (LBP), dan pembelajaran dengan algoritma *Learning Vector Quantization* (LVQ). Data yang digunakan adalah citra sidik jari jempol berukuran 200 x 300 piksel, berjenis keabuan dan berformat \*.jpg. Citra sidik jari terdiri dari 25 orang, masing-masing orang memiliki 6 data latih dan 2 data uji. Pengujian data latih dan data uji dilakukan kepada empat sistem yaitu sistem dengan jumlah ciri LBP = 8, 64, 128 dan 256 dan menggunakan masing-masing 2 buah data set dimana data set 1 berjumlah 15 orang dan data set 2 berjumlah 25 orang. Hasil pengujian keempat sistem menunjukkan bahwa sistem dengan jumlah ciri LBP = 128 merupakan sistem yang terbaik dengan kombinasi akurasi sistem yang tinggi dan juga waktu pembelajaran yang cepat.

**Kata kunci:** Identifikasi sidik jari, *Otsu thresholding*, *Local Binary Pattern* (LBP), jaringan syaraf tiruan, *Learning Vector Quantization* (LVQ).

### ABSTRACT

*Fingerprint is the generic structure in the form of a very detailed pattern and a sign that inherent in human beings. Many biometric systems using fingerprint as input data, because the nature of each individual is different although identical twins and do not change unless got a accident. The method used in this research is image segmentation using Otsu thresholding algorithm, feature extraction using Local Binary Pattern (LBP) algorithm and the learning method using Learning Vector Quantization (LVQ) algorithm. The used data is grayscale fingerprint image with 200x300 pixel and \*.jpg extension format. The fingerprint image is composed of 25 people, each person has 6 training data and 2 test data. Experiment of training data and test data conducted for four systems, namely the system with characteristics of LBP = 8, 64, 128 and 256 and their respective uses 2 pieces of data set where data set 1 amounted to 15 people and data set 2 amounted to 25 people. The fourth experiment results show that the system is a system with a number of LBP characteristics = 128 is a system with the best combination of high system accuracy and fast learning time.*

**Keywords:** fingerprint identification, *Otsu thresholding*, *Local Binary Pattern* (LBP), artificial neural networks, *Learning Vector Quantization* (LVQ).

## I. PENDAHULUAN

Sistem Biometrika merupakan teknologi yang mampu mengidentifikasi individu dari karakter fisik atau tingkah lakunya [1]. Salah satu karakter fisik yang paling banyak digunakan dalam sistem biometrika adalah sidik jari. Hal ini dikarenakan sifat dari sidik jari setiap individu berbeda meskipun kembar identik dan tidak berubah kecuali mendapat kecelakaan [2].

Sistem biometrika untuk mengidentifikasi sidik jari telah banyak dikembangkan dengan berbagai macam metode ekstraksi ciri, contohnya dengan menggunakan metode ekstraksi ciri struktur minutia atau perpotongan guratan-guratan kulit yang membentuk sidik jari manusia. Tetapi tidak semua metode ekstraksi ciri dapat menghasilkan akurasi yang baik dalam proses pengidentifikasian sidik jari. *Local Binary Pattern* (LBP) merupakan metode ekstraksi ciri berbasis tekstur yang akan membandingkan

sebuah nilai dari setiap piksel dengan nilai piksel tetangganya. Kemudian nilai baru yang didapatkan dari setiap piksel itu akan dijadikan sebuah histogram yang akan dijadikan ciri dari objek tersebut [3]. Hasil dari ekstraksi ciri LBP kemudian harus melewati tahap pembelajaran Jaringan Syaraf Tiruan (JST) agar mendapatkan hasil yang optimal.

*Learning Vector Quantization* (LVQ) merupakan salah satu metode dalam JST untuk melakukan pembelajaran pada lapisan kompetitif yang terawasi. Suatu lapisan kompetitif akan secara otomatis belajar untuk mengklasifikasikan vektor vektor input [4]. Penelitian ini akan menerapkan metode LBP dan LVQ untuk mengidentifikasi citra sidik jari.

## II. MATERI DAN METODE

### 2.1 Data Penelitian

Data yang digunakan dalam penelitian ini berupa data citra sidik jari berukuran 200 x 300 piksel, berjenis keabuan dan berformat \*.jpg. Citra sidik jari terdiri dari 25 orang, masing-masing orang memiliki 6 data latih dan 2 data uji. Total data latih 150 citra dan total data uji 50 citra, sehingga total jumlah keseluruhan citra adalah 200 citra sidik jari.

### 2.2 Sidik Jari

Sidik jari merupakan struktur genetika dalam bentuk pola yang sangat detail dan tanda yang melekat pada diri manusia [5]. Banyak sistem biometrika yang menggunakan sidik jari sebagai data masukan, hal ini dikarenakan sidik jari mempunyai beberapa keunggulan sifat dibandingkan ciri fisik yang lain, diantaranya:

- Perennial nature*, yaitu guratan-guratan pada sidik jari yang melekat pada kulit manusia seumur hidup.
- Immutability*, yaitu sidik jari seseorang tidak pernah berubah, kecuali mendapatkan kecelakaan.
- Individuality*, pola sidik jari adalah unik dan berbeda untuk setiap orang.

### 2.3 Segmentasi

Tujuan daripada segmentasi ialah membagi suatu citra menjadi wilayah-wilayah yang serupa berdasarkan kriteria keserupaan tertentu antara tingkat keabuan piksel, kemudian hasil dari proses segmentasi ini akan digunakan untuk proses tingkat lebih lanjut seperti proses identifikasi objek.

#### 2.3.1 Otsu thresholding

*Otsu thresholding* merupakan salah satu metode untuk mensegmentasi citra. Metode *otsu* akan membagi histogram citra keabuan kedalam dua daerah yang berbeda secara otomatis tanpa membutuhkan bantuan *user* untuk memasukkan nilai ambang. Berikut merupakan rumus yang digunakan untuk menentukan nilai ambang dengan menggunakan metode *otsu hresholding*:

$$\sigma_B^2(k^*) = \max_{0 \leq k \leq L} \sigma_B^2(k) \quad (2.1)$$

dengan:

$$\sigma_B^2(k) = \frac{[\mu_T \omega(k) - \mu(k)]^2}{\omega(k)[1 - \omega(k)]} \quad (2.2)$$

$$\mu_T = \sum_{i=0}^L i * P_i \quad (2.3)$$

$$\omega(k) = \sum_{k=0}^L P_k \quad (2.4)$$

$$\mu(k) = \sum_{k=0}^L k * P_k \quad (2.5)$$

dimana,  $\sigma_B^2(k^*)$  = varians antar kelas maksimum  
 $\sigma_B^2(k)$  = varians antar kelas  
 $\omega(k)$  = *Zeroth Cumulative Moment* level ke  $k$  (0..255)  
 $\mu(k)$  = *First Cumulative Moment* level ke  $k$  (0..255)  
 $\mu_T$  = total nilai rata-rata histogram ternormalisasi  
 $P_i$  = histogram ternormalisasi level ke  $i$  (0..255)  
 $P_k$  = histogram ternormalisasi level ke  $k$  (0..255)  
 $L$  = jumlah perbedaan tingkat intensitas ( $L = 255$ )

### 2.4 Local Binary Pattern (LBP)

*Local Binary Pattern* (LBP) merupakan salah satu metode ekstraksi ciri yang sederhana namun sangat efisien bagi identifikasi tekstur, dimana setiap piksel dalam sebuah citra diibandingkan dengan


piksel-piksel di sekelilingnya dan menjadikan hasil perhitungannya sebagai nilai biner [6]. Untuk mengambangkan satu piksel dengan piksel-piksel disekelilingnya, digunakanlah sebuah sirkular blok piksel yang umumnya berukuran ( $P = 8, R = 1$ ). Ukuran dari sirkular blok piksel dapat diubah dengan menentukan jarak dan jumlah piksel tetangga dengan menggunakan rumus sebagai berikut:

$$x_i = x_c + R \cos\left(\frac{2\pi i}{P}\right) \quad (2.6)$$

$$y_i = y_c + R \sin\left(\frac{2\pi i}{P}\right) \quad (2.7)$$

dimana,  $x_c, y_c$  = koordinat dari piksel tengah  
 $x_i, y_i$  = koordinat dari piksel tetangga  
 $R$  = jarak  
 $P$  = jumlah piksel tetangga  
 $i$  = bernilai 0 sampai  $P - 1$

Gambar 1 memberikan contoh beberapa sirkular blok piksel dengan jarak dan jumlah piksel tetangga yang berbeda.



**Gambar 1. Sirkular blok piksel LBP (8,1), (16,2), dan (24,3)**

Adapun rumus yang digunakan untuk menghitung ciri dari metode LBP adalah sebagai berikut:

$$LBP_{P,R}(x_c, y_c) = \sum_{i=0}^{P-1} s(g_i - g_c) 2^i \quad (2.8)$$

dimana,  $x_c, y_c$  = koordinat piksel di titik  $x, y$   
 $P$  = jumlah piksel tetangga  
 $R$  = jarak  
 $g_i$  = piksel blok ketetanggaan pada posisi ke  $i$   
 $g_c$  = piksel tengah blok  
 $s(x) = \begin{cases} 1 & x \geq 0 \\ 0 & x < 0 \end{cases}$

## 2.5 Jaringan Syaraf Tiruan

Jaringan Syaraf Tiruan (JST) merupakan suatu sistem pemrosesan informasi yang mempunyai karakteristik menyerupai jaringan syaraf biologi. JST tercipta sebagai suatu generalisasi model matematis dari pemahaman manusia yang didasarkan atas asumsi sebagai berikut [7]:

- Pemrosesan informasi terjadi pada elemen sederhana yang disebut *neuron*.
- Sinyal mengalir diantara *neuron* melalui suatu sambungan penghubung.
- Setiap sambungan penghubung memiliki bobot yang bersesuaian. Bobot ini akan digunakan untuk mengalikan sinyal yang dikirim melaluinya.

Setiap *neuron* akan menerapkan fungsi aktivasi terhadap sinyal hasil penjumlahan berbobot yang masuk kepadanya untuk menentukan sinyal keluarannya.

### 2.5.1 Normalisasi


Sebelum melakukan tahap pembelajaran dalam sistem identifikasi sidik jari, data pelatihan akan dinormalisasi. Hal ini dikarenakan terdapat beberapa nilai histogram pada metode LBP yang memiliki tingkat kemunculan yang berbeda jauh dengan nilai histogram yang lainnya, sehingga data tersebut perlu dinormalisasikan. Normalisasi ini juga bertujuan untuk mendapatkan data dengan ukuran yang lebih kecil yang mewakili data asli tanpa kehilangan karakteristiknya sendiri [8]. Dalam penelitian ini digunakan rumus normalisasi *Min - Max* dengan penskalaan 0 sampai 1. Rumus dari normalisasi *Min - Max* adalah sebagai berikut:

$$X' = \frac{X - X_{min}}{X_{max} - X_{min}} \quad (2.9)$$

dimana  $X'$  = nilai ciri hasil normalisasi  
 $X$  = nilai ciri yang akan dinormalisasi  
 $X_{min}$  = nilai terkecil dari suatu ciri  
 $X_{max}$  = nilai terbesar dari suatu ciri

### 2.5.2 Learning Vector Quantization (LVQ)

Learning Vector Quantization (LVQ) adalah suatu metode untuk melakukan pembelajaran pada lapisan kompetitif yang terawasi. Suatu lapisan kompetitif akan secara otomatis belajar untuk mengklasifikasikan vektor-vektor input. Kelas-kelas yang didapatkan sebagai hasil dari lapisan kompetitif ini hanya tergantung pada jarak antara vektor-vektor input. Jika 2 vektor input mendekati sama, maka lapisan kompetitif akan meletakkan kedua vektor input tersebut ke dalam kelas yang sama [9]. Contoh arsitektur dari LVQ dapat dilihat pada gambar 2.



Gambar 2. Contoh arsitektur jaringan LVQ

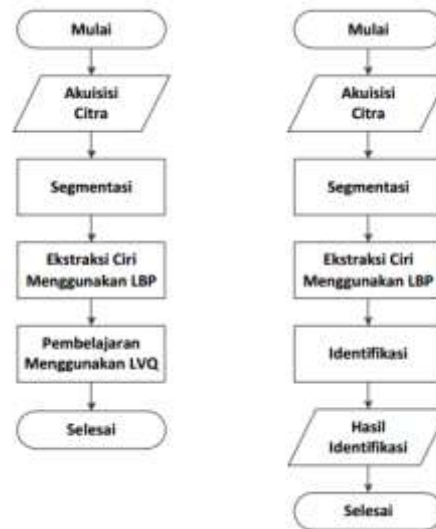
Berikut merupakan algoritma pembelajaran dari metode LVQ:

1. Tetapkan:
  - a. Bobot ( $w$ ).
  - b. Maksimum Epoch ( $MaxEpoch$ ).
  - c. Error minimum yang diharapkan ( $Eps$ ).
  - d. Laju pembelajaran ( $\alpha$ ).
2. Masukkan:
  - a. Input  $x(n,m)$ ;  $m$  = jumlah input,  $n$  = jumlah data.
  - b. Target  $T(1,n)$ .
3. Tetapkan kondisi awal:  $Epoch = 0$ .
4. Kerjakan jika: ( $Epoch < MaxEpoch$ ) atau ( $\alpha > Eps$ )
  - a.  $Epoch = Epoch + 1$ ;
  - b. Kerjakan untuk  $i = 1$  sampai  $n$ 
    - i. Tentukan  $j$  sedemikian hingga minimum dengan menggunakan rumus sebagai berikut:
 
$$C_j = \|x - w_j\| \quad (2.10)$$
    - ii. Perbaiki  $w_j$  dengan ketentuan:
      - Jika  $T = C_j$  maka:
 
$$w_j (baru) = w_j (lama) + \alpha (x - w_j (lama)) \quad (2.11)$$
      - Jika  $T \neq C_j$  maka:
 
$$w_j (baru) = w_j (lama) - \alpha (x - w_j (lama)) \quad (2.12)$$
  - c. Kurangi nilai laju pembelajaran dengan rumus sebagai berikut:
 
$$\alpha (baru) = \alpha (lama) - (0,1 * \alpha (lama)) \quad (2.13)$$

### 2.6 Tahapan Identifikasi Sidik Jari

Tahap identifikasi sidik jari terdiri dari 2 tahap yaitu tahap pembelajaran dan tahap identifikasi yang dapat dilihat pada gambar 3. Tahap pembelajaran terdiri dari beberapa proses yaitu proses segmentasi, proses ekstraksi ciri menggunakan metode LBP dan proses pembelajaran dengan metode LVQ. Hasil daripada tahap pembelajaran ini adalah bobot-bobot pada setiap target dari data peserta. Bobot-bobot ini kemudian disimpan dan akan digunakan pada tahap identifikasi.

Tahap identifikasi juga terdiri dari beberapa proses yaitu proses segmentasi, proses ekstraksi ciri menggunakan metode LBP dan proses identifikasi. Proses identifikasi membandingkan ciri citra yang telah diekstraksi dengan bobot pada setiap target yang telah tersimpan melalui pembelajaran LVQ. Target dengan hasil perbandingan nilai terkecil akan dipilih sebagai hasil identifikasi sidik jari.



Gambar 3 Flowchart identifikasi sidik jari: (a) tahap pembelajaran (b) tahap identifikasi

### III. HASIL DAN PEMBAHASAN

#### 3.1 Hasil Pengujian

Hal pertama yang dilakukan dalam menguji kinerja sistem adalah melatih sistem. Dalam melatih sistem digunakan 2 buah *data set* yang terdiri dari:

- Data set* pertama terdiri dari 15 orang dengan masing-masing orang memiliki 6 buah citra latih dan 2 citra uji sehingga total terdapat 90 citra latih dan 30 citra uji.
- Data set* kedua terdiri dari 25 orang dengan masing-masing orang memiliki 6 buah citra latih dan 2 citra uji sehingga total terdapat 150 citra latih dan 50 citra uji.

Kedua *data set* dilatih secara berulang-ulang menggunakan beberapa nilai pada ketiga parameter seperti *max epoch* (10 dan 100), *error minimum* (0,1, 0,01 dan 0,001) dan *learning rate* (0,1).

##### 3.1.1 Pengujian data latih dan data uji

Data latih merupakan kumpulan citra sidik jari yang melalui proses pembelajaran dalam sistem yang dibuat, sedangkan data uji adalah kumpulan citra sidik jari yang yang tidak dilibatkan dalam proses pembelajaran.

##### 3.1.1.1 Sistem dengan jumlah ciri LBP = 8

Sistem ini membagi 256 ciri LBP ke beberapa *range* nilai tertentu sehingga ciri LBP menjadi 8 ciri. Tabel 1 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* pertama, sedangkan tabel 2 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* kedua.

Tabel 1. Salah satu contoh hasil pelatihan *data set 1* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 8

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss:ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 85,56%     | 73,33%   | 82,50% | 00:09:290                |
|    |                  | LBP (8,2) | 100                    | 0,001         | 0,1           | 44    | 80,00%     | 66,67%   | 76,67% | 00:38:555                |
|    |                  | LBP (8,3) | 10                     | 0,01          | 0,1           | 10    | 80,00%     | 76,67%   | 79,17% | 00:09:143                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 84,44%     | 80,00%   | 83,33% | 00:00:879                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 87,78%     | 76,67%   | 85,00% | 00:07:885                |
|    |                  | LBP (8,2) | 100                    | 0,1           | 0,1           | 1     | 78,89%     | 73,33%   | 77,50% | 00:00:922                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 80,00%     | 80,00%   | 80,00% | 00:00:972                |
|    |                  | LBP (8,4) | 10                     | 0,01          | 0,1           | 10    | 83,33%     | 86,67%   | 84,17% | 00:08:387                |

Tabel 2. Salah satu contoh hasil pelatihan *data set 2* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 8

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 100                    | 0,01          | 0,1           | 22    | 79,33%     | 68,00%   | 76,50% | 00:49:824                |
|    |                  | LBP (8,2) | 100                    | 0,01          | 0,1           | 22    | 79,33%     | 64,00%   | 75,50% | 00:51:146                |
|    |                  | LBP (8,3) | 100                    | 0,01          | 0,1           | 22    | 76,67%     | 66,00%   | 74,00% | 00:49:943                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 76,67%     | 68,00%   | 74,50% | 00:02:477                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 80,67%     | 72,00%   | 78,50% | 00:02:114                |
|    |                  | LBP (8,2) | 10                     | 0,01          | 0,1           | 10    | 80,00%     | 66,00%   | 76,50% | 00:24:388                |
|    |                  | LBP (8,3) | 100                    | 0,001         | 0,1           | 44    | 76,67%     | 62,00%   | 73,00% | 01:43:035                |
|    |                  | LBP (8,4) | 100                    | 0,001         | 0,1           | 44    | 74,00%     | 70,00%   | 73,00% | 01:44:226                |

### 3.1.1.2 Sistem dengan jumlah ciri LBP = 64

Sistem ini membagi 256 ciri LBP ke beberapa *range* nilai tertentu sehingga ciri LBP menjadi 64 ciri. Tabel 3 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* pertama, sedangkan tabel 4 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* kedua.

**Tabel 3.** Salah satu contoh hasil pelatihan *data set 1* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 64

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 86,67%     | 66,67%   | 81,67% | 00:10:461                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 91,11%     | 83,33%   | 89,17% | 00:01:089                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 87,78%     | 83,33%   | 86,67% | 00:01:030                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 87,78%     | 80,00%   | 85,83% | 00:01:078                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 84,44%     | 66,67%   | 80,00% | 00:00:993                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 88,89%     | 83,33%   | 87,50% | 00:01:095                |
|    |                  | LBP (8,3) | 10                     | 0,01          | 0,1           | 10    | 87,78%     | 80,00%   | 85,83% | 00:11:268                |
|    |                  | LBP (8,4) | 10                     | 0,01          | 0,1           | 10    | 82,22%     | 76,67%   | 80,83% | 00:10:701                |

**Tabel 4.** Salah satu contoh hasil pelatihan *data set 2* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 64

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 100                    | 0,001         | 0,1           | 44    | 84,00%     | 68,00%   | 80,00% | 01:58:926                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 87,33%     | 80,00%   | 85,50% | 00:02:742                |
|    |                  | LBP (8,3) | 100                    | 0,01          | 0,1           | 22    | 84,00%     | 74,00%   | 81,50% | 00:59:231                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 84,00%     | 62,00%   | 78,50% | 00:02:853                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 82,67%     | 74,00%   | 80,50% | 00:02:778                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 87,33%     | 86,00%   | 87,00% | 00:02:803                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 82,67%     | 76,00%   | 81,00% | 00:02:865                |
|    |                  | LBP (8,4) | 100                    | 0,01          | 0,1           | 22    | 83,33%     | 76,00%   | 81,50% | 01:00:346                |

### 3.1.1.3 Sistem dengan jumlah ciri LBP = 128

Sistem ini membagi 256 ciri LBP ke beberapa *range* nilai tertentu sehingga ciri LBP menjadi 128 ciri. Tabel 5 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* pertama, sedangkan tabel 6 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* kedua.

### 3.1.1.4 Sistem dengan jumlah ciri LBP = 256

Sistem ini menggunakan jumlah keseluruhan dari ciri yang diperoleh dengan menggunakan metode LBP, dimana apabila  $P$  (jumlah piksel tetangga) = 8, maka total ciri adalah  $2^8 = 256$  buah ciri. Tabel 7 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* pertama, sedangkan tabel 8 menunjukkan salah satu contoh hasil pengujian sistem tertinggi pada *data set* kedua.

**Tabel 5.** Salah satu contoh hasil pelatihan *data set 1* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 128

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 90,00%     | 76,67%   | 86,67% | 00:12:507                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 93,33%     | 80,00%   | 90,00% | 00:01:196                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 90,00%     | 86,67%   | 89,17% | 00:01:218                |
|    |                  | LBP (8,4) | 10                     | 0,01          | 0,1           | 10    | 88,89%     | 83,33%   | 87,50% | 00:12:318                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 85,56%     | 76,67%   | 83,33% | 00:01:194                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 90,00%     | 76,67%   | 86,67% | 00:01:278                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 90,00%     | 80,00%   | 87,50% | 00:01:206                |
|    |                  | LBP (8,4) | 100                    | 0,01          | 0,1           | 22    | 86,67%     | 80,00%   | 85,00% | 00:27:073                |

Tabel 6. Salah satu contoh hasil pelatihan *data set 2* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 128

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 85,33%     | 76,00%   | 83,00% | 00:03:192                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 88,00%     | 74,00%   | 84,50% | 00:03:080                |
|    |                  | LBP (8,3) | 100                    | 0,01          | 0,1           | 22    | 88,00%     | 76,00%   | 85,00% | 01:17:062                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 86,67%     | 64,00%   | 81,00% | 00:03:621                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 84,00%     | 76,00%   | 82,00% | 00:32:518                |
|    |                  | LBP (8,2) | 10                     | 0,01          | 0,1           | 10    | 86,67%     | 84,00%   | 86,00% | 00:31:996                |
|    |                  | LBP (8,3) | 10                     | 0,01          | 0,1           | 10    | 85,33%     | 78,00%   | 83,50% | 00:32:748                |
|    |                  | LBP (8,4) | 10                     | 0,01          | 0,1           | 10    | 84,67%     | 80,00%   | 83,50% | 00:33:385                |

Tabel 7. Salah satu contoh hasil pelatihan *data set 1* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 256

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 90,00%     | 83,33%   | 88,33% | 00:01:854                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 92,22%     | 80,00%   | 89,17% | 00:01:723                |
|    |                  | LBP (8,3) | 10                     | 0,01          | 0,1           | 10    | 90,00%     | 83,33%   | 88,33% | 00:17:442                |
|    |                  | LBP (8,4) | 10                     | 0,1           | 0,1           | 1     | 86,67%     | 80,00%   | 85,00% | 00:01:716                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 88,89%     | 80,00%   | 86,67% | 00:01:787                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 92,22%     | 76,67%   | 88,33% | 00:01:700                |
|    |                  | LBP (8,3) | 10                     | 0,1           | 0,1           | 1     | 88,89%     | 73,33%   | 85,00% | 00:01:714                |
|    |                  | LBP (8,4) | 100                    | 0,01          | 0,1           | 22    | 86,67%     | 70,00%   | 82,50% | 00:37:434                |

Tabel 8. Salah satu contoh hasil pelatihan *data set 2* dengan akurasi sistem tertinggi menggunakan sistem dengan ciri LBP = 256

| No | Cross Validation | Nama Ciri | Parameter Pembelajaran |               |               |       | Akurasi    |          |        | Waktu Belajar (mm:ss.ms) |
|----|------------------|-----------|------------------------|---------------|---------------|-------|------------|----------|--------|--------------------------|
|    |                  |           | Max Epoch              | Error Minimum | Learning Rate | Epoch | Data Latih | Data Uji | Sistem |                          |
| 1  | Cross 1          | LBP (8,1) | 10                     | 0,1           | 0,1           | 1     | 86,00%     | 78,00%   | 84,00% | 00:04:761                |
|    |                  | LBP (8,2) | 10                     | 0,1           | 0,1           | 1     | 88,00%     | 78,00%   | 85,50% | 00:04:453                |
|    |                  | LBP (8,3) | 100                    | 0,01          | 0,1           | 22    | 88,67%     | 72,00%   | 84,50% | 01:41:562                |
|    |                  | LBP (8,4) | 100                    | 0,001         | 0,1           | 44    | 85,33%     | 66,00%   | 80,50% | 03:25:626                |
| 2  | Cross 2          | LBP (8,1) | 10                     | 0,01          | 0,1           | 10    | 86,67%     | 78,00%   | 84,50% | 00:45:410                |
|    |                  | LBP (8,2) | 10                     | 0,01          | 0,1           | 10    | 88,00%     | 82,00%   | 86,50% | 00:46:062                |
|    |                  | LBP (8,3) | 100                    | 0,01          | 0,1           | 22    | 86,67%     | 78,00%   | 84,50% | 01:40:766                |
|    |                  | LBP (8,4) | 10                     | 0,01          | 0,1           | 10    | 82,67%     | 76,00%   | 81,00% | 00:45:994                |

### 3.2 Pembahasan

Hasil dari pengujian keempat sistem dapat dikatakan cukup baik, akan tetapi didapati juga beberapa citra tidak dapat dikenali dengan tepat. Hal ini disebabkan oleh:

- Semakin banyak jumlah data maka metode ekstraksi ciri semakin tidak bisa mempresentasikan ciri dari sidik jari seseorang dengan baik.
- Citra sidik jari yang digunakan memiliki tingkat kemiripan yang cukup rendah antara citra yang satu dengan yang lainnya dari orang yang sama.

Tabel 9 dan 10 merupakan perbandingan akurasi sistem dan waktu pembelajaran antar sistem.

Tabel 9. Perbandingan rata-rata akurasi sistem tertinggi

| Data Set | Cross Validation | Ukuran LBP | Rata-Rata Akurasi Sistem Tertinggi |        |        |        |
|----------|------------------|------------|------------------------------------|--------|--------|--------|
|          |                  |            | Jumlah Ciri LBP                    |        |        |        |
|          |                  |            | 8                                  | 64     | 128    | 256    |
| 1        | $\frac{1+2}{2}$  | LBP (8,1)  | 83,75%                             | 80,84% | 85,00% | 87,50% |
|          |                  | LBP (8,2)  | 77,09%                             | 88,34% | 88,34% | 88,75% |
|          |                  | LBP (8,3)  | 79,59%                             | 86,25% | 88,34% | 86,67% |
|          |                  | LBP (8,4)  | 83,75%                             | 83,33% | 86,25% | 83,75% |
| 2        | $\frac{1+2}{2}$  | LBP (8,1)  | 77,50%                             | 80,25% | 82,50% | 84,25% |
|          |                  | LBP (8,2)  | 76,00%                             | 86,25% | 85,25% | 86,00% |
|          |                  | LBP (8,3)  | 73,50%                             | 81,25% | 84,25% | 84,50% |
|          |                  | LBP (8,4)  | 73,75%                             | 80,00% | 82,25% | 80,75% |

Tabel 10. Perbandingan rata-rata waktu pembelajaran semua percobaan pengujian

| Data Set | Ukuran LBP | Rata-Rata Waktu Pembelajaran |           |           |           |
|----------|------------|------------------------------|-----------|-----------|-----------|
|          |            | Jumlah Ciri LBP              |           |           |           |
|          |            | 8                            | 64        | 128       | 256       |
| 1        | LBP (8,1)  | 00:12:060                    | 00:15:180 | 00:17:700 | 00:25:980 |
|          | LBP (8,2)  | 00:12:780                    | 00:15:000 | 00:17:076 | 00:26:280 |
|          | LBP (8,3)  | 00:13:380                    | 00:15:120 | 00:17:082 | 00:25:440 |
|          | LBP (8,4)  | 00:12:840                    | 00:15:120 | 00:17:720 | 00:25:920 |
| 2        | LBP (8,1)  | 00:32:280                    | 00:39:960 | 00:47:040 | 01:06:120 |
|          | LBP (8,2)  | 00:33:720                    | 00:39:560 | 00:46:860 | 01:06:120 |
|          | LBP (8,3)  | 00:32:070                    | 00:39:780 | 00:47:400 | 01:07:440 |
|          | LBP (8,4)  | 00:33:030                    | 00:40:020 | 00:47:580 | 01:07:740 |

#### IV. KESIMPULAN DAN SARAN

##### 4.1 Kesimpulan

Berdasarkan hasil pengujian terhadap keempat sistem yang dibangun, dapat disimpulkan bahwa sistem dengan jumlah ciri LBP = 128 menghasilkan akurasi yang tinggi. Adapun waktu pembelajaran pada masing-masing sistem sangat dipengaruhi oleh jumlah data yang digunakan, dan nilai parameter seperti *max epoch*, *error minimum* dan *learning rate*.

##### 4.2 Saran

Pada penelitian selanjutnya, sistem dapat dikembangkan lagi dengan menggunakan variasi ukuran sirkular blok piksel dan menambah jumlah ciri dari metode LBP.

#### DAFTAR PUSTAKA

- [1] Santi R. C. N., 2008, Identifikasi Biometrik Sidik Jari dengan Metode Fraktal, *Jurnal Teknologi Informasi DINAMIK*, No. 1, Volume XIII, 68-72.
- [2] Arifin dan Tumana O., 2011, Pengenalan Pola Sidik Jari Menggunakan Jaringan Syaraf Tiruan dengan Metode Pembelajaran *Backpropagation*, *Jurnal Aplikasi Fisika*, No. 1, Volume VII, 1-11.
- [3] Kastella S. M., 2012, Simulasi Sistem Pengenalan Individu Berdasarkan Hidung Tampak Samping Menggunakan Metode *Local Binary Pattern* dan Jaringan Syaraf Tiruan-*Learning Vector Quantization*, *Skripsi*, Jurusan Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom, Bandung.
- [4] Ranadhi D., 2006, Implementasi *Learning Vector Quantization* (LVQ) untuk Pengenal Pola Sidik Jari Pada Sistem Informasi Narapidana LP Wirogunan, *Skripsi*, Jurusan Teknik Informatika, Fakultas Teknik Industri, Universitas Islam Indonesia, Yogyakarta.
- [5] Misbach I. H., 2010, *Dahsyatnya Sidik Jari*, Visimedia, Jakarta.
- [6] Pietikäinen, M., 2010, Local Binary Patterns, *Scholarpedia*, No. 3, Vol. 5, 9775, [http://www.scholarpedia.org/article/Local\\_Binary\\_Patterns](http://www.scholarpedia.org/article/Local_Binary_Patterns).
- [7] Widodo T. S., 2005, *Sistem Neuro Fuzzy untuk Pengolahan Informasi, Pemodelan, dan Kendali*, Graha Ilmu, Yogyakarta.



- [8] Indrabayu dkk., 2012, Prediksi Curah Hujan dengan Jaringan Saraf Tiruan, Hasil Penelitian Fakultas Teknik, Volume VI, ISBN : 978-979-127255-0-6.
- [9] Kusumadewi S., 2003, *Artificial Intelligence (Teknik dan Aplikasinya)*, Graha Ilmu, Yogyakarta.