

PENGENALAN WAJAH MENGGUNAKAN METODE *LOCAL BINARY PATTERN* DAN *PRINCIPAL COMPONENT ANALYSIS*

Hizas Sabibal Rasyad¹, Febryanti Sthevanie.², Anditya Arifanto.³

^{1,2,3}Fakultas Informatika, Universitas Telkom, Bandung

¹hizassr@students.telkomuniversity.ac.id, ²ssthevanie@telkomuniversity.ac.id, ³anditya@telkomuniversity.ac.id

Abstrak

Pengenalan Wajah merupakan sistem teknologi berbasis biometrik yang digunakan untuk mengidentifikasi seseorang dari suatu gambar digital ataupun video dengan cara menganalisa wajah mereka menggunakan algoritma tertentu. Meningkatkan akurasi pada pengenalan wajah menjadi sebuah tantangan bagi peneliti. Pada penelitian sebelumnya[1], pengenalan wajah menggunakan ekstraksi fitur *Local Binary Pattern* pada resolusi rendah 35 piksel telah mencapai akurasi 90%. Pada penelitian ini, penulis membuat system pengenalan wajah menggunakan metode *Local Binary Pattern* dan dikombinasikan dengan *Principal Component Analysis* untuk meningkatkan penelitian sebelumnya, dan berhasil mencapai akurasi 94% pada resolusi rendah.

Kata kunci : Pengenalan Wajah, *Local Binary Pattern*, *Principal Component Analysis*, Ekstraksi Fitur

Abstract

Face Recognition is a biometric-based technology system that is used to identify someone from a digital image or video by analyzing their faces using certain algorithms. Increasing accuracy in facial recognition is a challenge for researchers. In previous studies [1], face recognition using features extraction of Local Binary Pattern features at a low resolution of 35 pixel has reached 90% accuracy. In this study, the author made a face recognition system using the Local Binary Pattern method and combined it with the Principal Component Analysis to improve previous research, and achieved 94% accuracy at low resolution.

Keywords: *Face Recognition, Local Binary Pattern, Principal Component Analysis, Feature Extraction*

1. Pendahuluan

1.1 Latar Belakang

Pada era modern ini, pengenalan wajah menjadi hal yang penting dan banyak digunakan pada beberapa aplikasi seperti untuk kehadiran otomatis, keamanan, pengawasan dan sebagainya. Salah satu tantangan pada pengenalan wajah ialah resolusi rendah pada citra digital atau video, yang dapat disebabkan oleh jarak wajah terdeteksi ataupun kualitas kamera yang digunakan. Akurasi pengenalan wajah pada resolusi rendah menjadi topik yang banyak diteliti untuk ditingkatkan. Pada penelitian sebelumnya, pengenalan wajah pada resolusi rendah menggunakan algoritma *Local Binary Pattern (LBP)* telah mencapai akurasi 90%. Pada tugas akhir ini, penulis akan membuat sistem pengenalan wajah menggunakan kombinasi dari metode *LBP* dengan salah satu metode reduksi dimensi, yakni *Principal Component Analysis (PCA)*. Dengan mengkombinasikan *LBP* dengan *PCA*, diharapkan dapat meningkatkan performa pengenalan wajah dalam akurasi dan kecepatan.

1.2 Topik dan Batasannya

Pada penelitian ini dilakukan studi dan pengimplementasian pengenalan wajah dengan menggunakan kombinasi metode *LBP* dengan *PCA*. Penulis memilih mengkombinasikan *LBP* dengan metode *PCA*, karena dibutuhkan reduksi fitur yang dapat menjaga fitur-fitur yang penting agar tidak hilang sehingga dapat meningkatkan performa akurasi dan kecepatan pengenalan wajah yang dilakukan, dan juga dengan menggunakan *PCA* data diprojektikan pada ruang vektor yang baru sehingga lebih mudah untuk diklasifikasi. Berdasarkan topik ini, penulis mengangkat beberapa rumusan masalah sebagai berikut :

1. Bagaimana membangun sistem pengenalan wajah menggunakan kombinasi metode *LBP* dan *PCA*?
2. Bagaimana parameter *LBP* yang terbaik untuk akurasi pengenalan wajah resolusi rendah yang maksimal?
3. Bagaimana parameter *PCA* yang terbaik untuk mengambil fitur-fitur yang seperlunya sehingga meningkatkan akurasi dan kecepatan pengenalan wajah resolusi rendah?

Dan batasan masalah dari penelitian ini adalah :

1. Sistem yang dibangun mengolah wajah yang sudah terdeteksi, menggunakan library *OpenCV Haar Cascade Face Detection*, dan merupakan library yang digunakan juga pada penelitian sebelumnya
2. Sistem yang dibangun melakukan pengenalan wajah pada citra dengan resolusi rendah yakni 35 x 35 pixel
3. Parameter *LBP* dari sistem yang dibangun hanya menggunakan 8 titik ketetangan
4. Pengenalan wajah yang dilakukan hanya pada wajah yang tidak menggunakan aksesoris apapun

5. Kondisi citra wajah data *train* dan data *test* diambil pada waktu dan hari yang sama.

1.3 Tujuan

Penelitian ini bertujuan untuk membangun sistem pengenalan wajah resolusi rendah menggunakan metode *Local Binary Pattern* dan *Principal Component Analysis* untuk dibandingkan dengan penelitian sebelumnya[1], menentukan dan menganalisa parameter terbaik pada metode tersebut. Parameter yang dimaksud yakni radius pada *LBP*, dan *n-component* pada *PCA*.

1.4 Organisasi Tulisan

Bagian selanjutnya penulis akan menjelaskan studi terkait, sistem yang dibangun, evaluasi, dan kesimpulan. Pada bagian studi terkait menjelaskan studi literatur atau teori yang menjadi dasar dari pengembangan dan pelaksanaan yang dilakukan pada penelitian ini. Pada bagian sistem yang dibangun menjelaskan mengenai rancangan dan implementasi sistem. Pada bagian evaluasi akan menampilkan hasil pengujian dan akan menjelaskan hasil pengujian pada penelitian. Bagian Kesimpulan menjelaskan kesimpulan yang didapatkan dari hasil pengujian dan analisis hasil pengujian.

2. Studi Terkait

2.1 Citra Digital

Citra Digital adalah fungsi kontinu dari intensitas cahaya yang direpresentasikan pada bidang dua dimensi. Fungsi citra digital dapat dinyatakan dalam bentuk fungsi intensitas cahaya yakni $f(x,y)$, dimana variabel x dan y merupakan koordinat spasial dari posisi piksel-piksel pada citra[3]. Citra digital dapat diformulasikan dengan persamaan :


$$f(x,y) \approx \begin{bmatrix} f(0,0) & f(0,1) & \dots & f(0,M-1) \\ f(1,0) & f(1,1) & \dots & f(1,M-1) \\ \vdots & \vdots & \vdots & \vdots \\ f(N-1,0) & f(N-1,1) & \dots & f(N-1,M-1) \end{bmatrix} \quad (2,1)$$

2.2 Local Binary Pattern

LBP adalah salah satu metode ekstraksi fitur dari suatu citra digital. Metode ini diperkenalkan oleh Ojala et al pada tahun 1996. *Local Binary Pattern* digunakan untuk mendapatkan tekstur dan bentuk dari suatu citra digital dengan cara menghitung perbandingan lebih besar atau kecil setiap piksel dengan piksel ketetanggaan [2]. Fitur yang didapat di setiap piksel berupa pola biner yang mewakili piksel tersebut. Setiap pola biner yang didapat kemudian dikonversi menjadi angka desimal kemudian disatukan untuk membentuk fitur histogram yang merupakan representasi dari citra digital tersebut. *Local Binary Pattern* dapat diformulasikan sebagai berikut :

$$LBP_{P,R}(x,y) = \sum_{p=0}^{P-1} s(g_p - g_c) 2^p$$

$$s(z) = \begin{cases} 1, & z \geq 0 \\ 0, & z < 0 \end{cases} \quad (2,2)$$



Gambar 2.1 Ilustrasi Local Binary Pattern

2.3 Principal Component Analysis

Principal *PCA* adalah metode untuk mereduksi dimensi dari suatu fitur dengan mentransformasikan data fitur ke bidang vektor yang baru dan menghilangkan fitur-fitur yang memiliki variansi yang rendah[4]. Langkah-langkah algoritma *PCA* adalah sebagai berikut :

1. Menghitung rata-rata (*mean*), dengan menggunakan persamaan :

$$\bar{X} = \frac{\sum X}{N} \quad (2,3)$$

Dimana \bar{x} adalah rata-rata (*mean*), x adalah data pada matriks, dan N adalah jumlah data.

2. Menghitung *covariance matrix*, dengan menggunakan persamaan :

$$Cov(A) = \frac{(A-\bar{X})*(A-\bar{X})^T}{N-1} \quad (2,4)$$

Dimana A adalah matriks data, \bar{X} adalah rata-rata (*mean*), N adalah jumlah data.

3. Menghitung *eigenvalue* dan *eigenvector* , dengan persamaan :

$$|A - \lambda I| = 0 \quad (2,5)$$

$$\sum V_i = \lambda_i V_i \quad (2,6)$$

Dimana A adalah matriks data, I adalah matriks identitas, λ *eigenvalue*, V adalah *eigenvector*, i adalah dimensi

4. Menghitung matriks pada ruang *PCA*, dengan persamaan :

$$B = V^T * A \quad (2,7)$$

Dimana V^T adalah *eigenvector* yang telah ditranspose, dan A adalah matriks data, dan B matriks pada ruang *PCA*.

2.4 K-Nearest Neighbors

K-Nearest Neighbor merupakan suatu metode klasifikasi dimana data-data diklasifikasikan berdasarkan mayoritas pada *K-NN (Nearest Neighbor)* atau tetangga terdekat [5]. Tetangga terdekat yang dimaksud ialah data-data yang terdapat pada Data Train. Pengukuran jarak dengan data tetangga dilakukan menggunakan *Euclidean distance*.

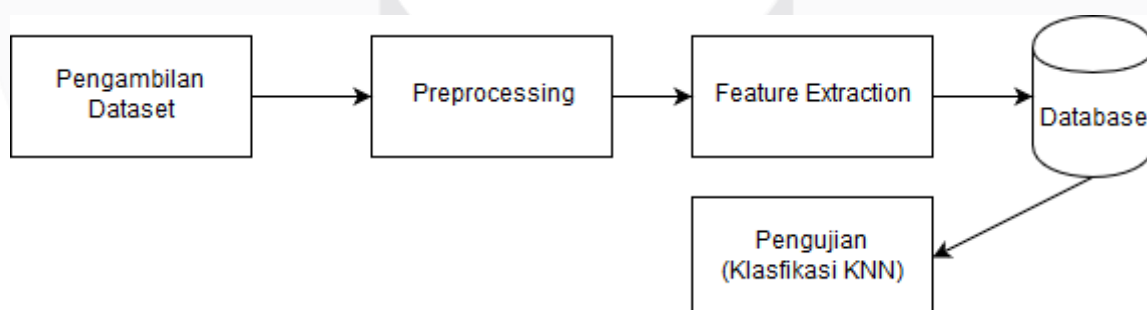
2.5 Haar Cascade Classifier

Haar Cascade Classifier merupakan metode *object detection* yang dapat digunakan untuk mendeteksi wajah pada suatu citra digital. Metode ini bekerja dengan cara mendeteksi fitur haar pada suatu citra yang berupa kombinasi-kombinasi kotak yang berisikan 1 bidang gelap dan 1 bidang terang [6].

3. Sistem yang Dibangun

3.1 Gambaran Umum Sistem

Terdapat 3 tahap utama dalam membangun sistem pengenalan wajah ini, yakni pengumpulan dataset, preprocessing, dan feature extraction.



Gambar 3.1 Gambaran Umum Sistem

3.1 Dataset

Data yang digunakan adalah berupa citra-citra yang diambil pada ruang kelas Telkom University menggunakan kamera. Citra berupa skenario mahasiswa-mahasiswa yang memasuki ruang kelas. Terdapat 6 orang mahasiswa, yakni “Ari”, “Adi”, “Hizas”, “Irfan”, “Prima”, dan “Nabil”. Setiap mahasiswa akan dijadikan label atau kelas untuk diklasifikasi. Dari penelitian ini didapatkan 579 citra untuk digunakan sebagai Data Train dan 280 yang didapatkan untuk digunakan sebagai Data Test.



Gambar 3.2 Contoh Data Train (Mahasiswa “Nabil”)



Gambar 3.3 Contoh Data Test (Mahasiswa “Hizas”)

3.2 Preprocessing

3.2.1 RGB to Grayscale

Dataset citra-citra diubah ruang warnanya dari RGB menjadi *Grayscale*.



Gambar 3.4 Citra *Grayscale*

3.2.2 Face Detection

Setiap citra grayscale yang dihasilkan akan diproses untuk dicek apakah terdapat wajah didalamnya menggunakan Haar Face Detection. Image wajah yang terdeteksi akan diambil dan diubah resolusi ukurannya menjadi 35x35.



Gambar 3.5 *Detected Face 35x35*

3.3 Feature Extraction

3.3.1 Local Binary Pattern

Image-image wajah yang didapat akan diekstrak fiturnya menggunakan *Local Binary Pattern*. Fitur yang didapat berupa tekstur wajah, yang kemudian setiap nilai-nilai pikselnya dimasukkan kedalam histogram sehingga dihasilkan histogram yang berisikan frekuensi nilai 1 sampai dengan 255.



Gambar 3.6 *LBP Face Texture*

3.3.2 Principal Component Analysis

Histogram yang dihasilkan dari ekstraksi fitur sebelumnya akan diproyeksikan dalam ruang vektor yang baru dan dilakukan reduksi dimensi. Fitur dari proses ini kemudian disimpan dan dijadikan sebagai karakteristik akhir dari wajah mahasiswa untuk pengujian menggunakan Klasifikasi KNN pada tahap pengujian.

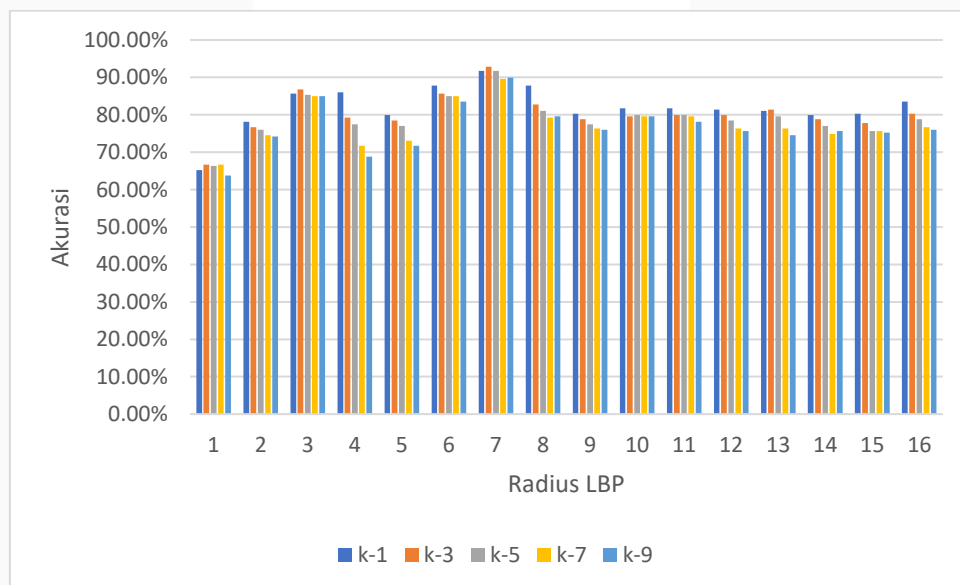
4. Evaluasi

4.1 Proses Pengujian

Pengujian dilakukan dengan melalui tahap yakni menentukan parameter *LBP* terbaik kemudian menentukan parameter *PCA* terbaik. Dilakukan *looping* untuk membandingkan akurasi yang dihasilkan pada masing-masing parameter.


4.2 Hasil Pengujian

4.2.1 Hasil dengan metode *LBP*



Gambar 4.1 Grafik Akurasi Metode *LBP*


Grafik diatas merupakan perbandingan akurasi hasil klasifikasi pada masing-masing radius *LBP* dari radius 1 sampai dengan 16 menggunakan klasifikasi KNN. Akurasi tertinggi didapat pada *LBP* dengan parameter radius 7 pada k-3 dengan akurasi 92.47%.



Gambar 4.2 Rata-Rata Akurasi LBP

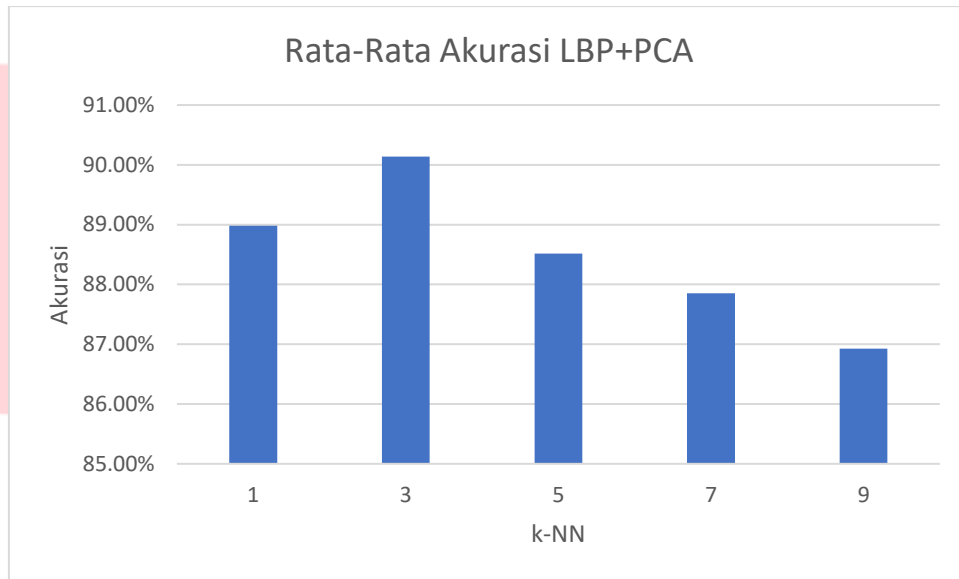
Grafik diatas merupakan perbandingan rata-rata akurasi LBP semua radius pada masing-masing k tetangga yang digunakan pada klasifikasi KNN. Akurasi paling tinggi didapatkan pada k = 1 dengan akurasi 82.01%, dan akurasi menurun seiring bertambahnya nilai k.

4.2.2 Hasil dengan metode LBP+PCA



Gambar 4.3 Grafik Akurasi Metode LBP+PCA

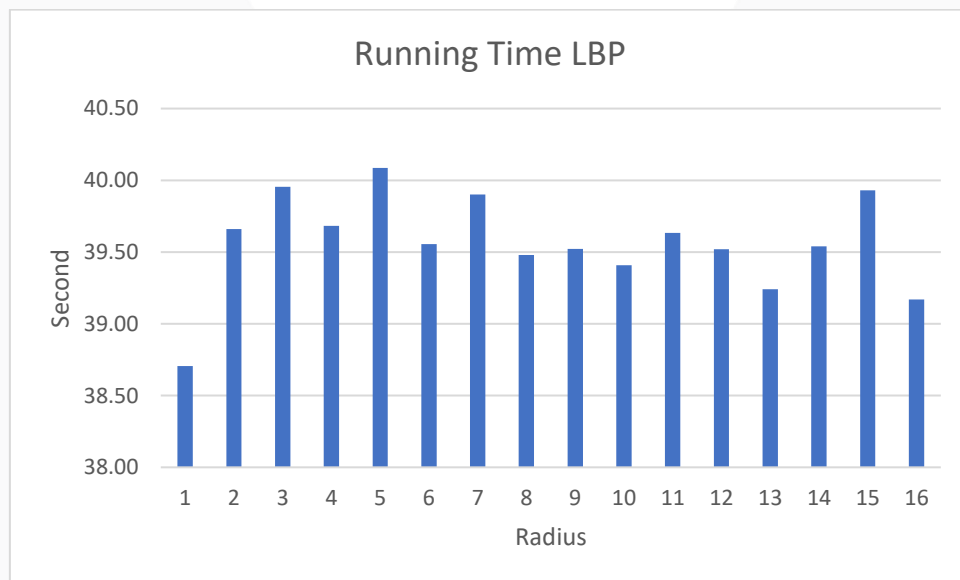
Grafik diatas merupakan perbandingan akurasi hasil klasifikasi dengan menggunakan LBP radius 7 dikombinasikan dengan n-First Principal Component dari 1 sampai dengan 70. Akurasi tertinggi didapat pada n-First Principal Component 18 pada k-3 dengan nilai akurasi 94.98%.



Gambar 4.4 Grafik Rata-Rata Akurasi *LBP+PCA*.

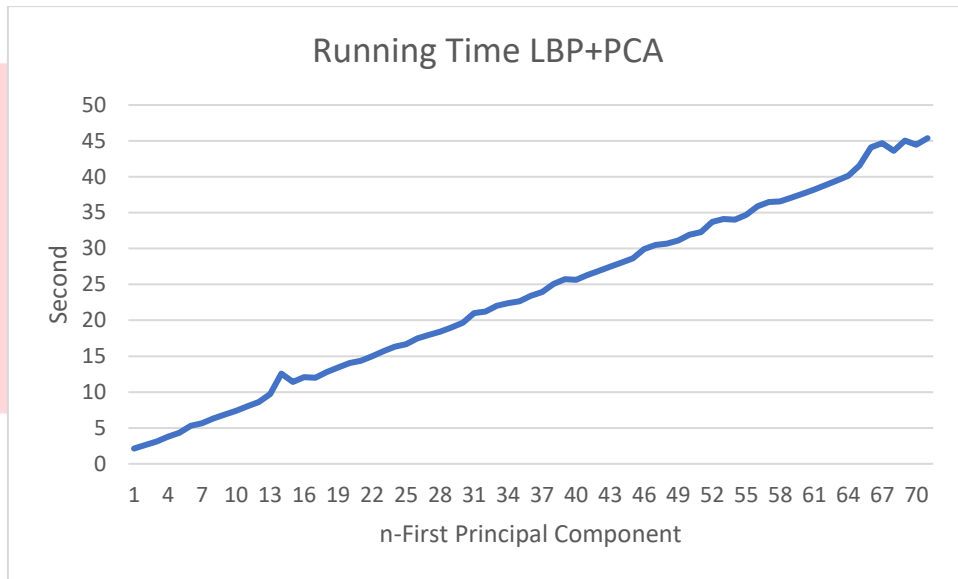
Grafik diatas merupakan perbandingan rata-rata akurasi *LBP+PCA* semua n-First Principal Component (dari 1-70) pada masing-masing k tetangga yang digunakan pada klasifikasi KNN. Akurasi tertinggi didapat pada nilai k = 3 sebesar 90.14%.

4.2.3 Perbandingan Running Time *LBP* dengan *LBP+PCA*



Gambar 4.5 Grafik Running Time *LBP*


Rentang running time : 38s-40s



Gambar 4.6 Grafik Running Time *LBP+PCA*

Running time *LBP+PCA* meningkat seiring bertambahnya n-First Principal Component yang digunakan.

4.2.4 Kesalahan Rekognisi



Gambar 4.7 Wajah-wajah yang salah direkognisi

Pada akurasi terbaik (n -First Principal Component = 14, k -3), terdapat 24 wajah yang salah dikenali oleh sistem. 2 wajah dengan label “Prima” terdeteksi sebagai “Ari”, 3 wajah dengan label “Nabil” terdeteksi sebagai “Ari”, dan 21 wajah dengan label “Irfan” terdeteksi sebagai “Ari”.

4.3 Analisis Hasil Pengujian

4.3.1 Metode *LBP*

Berdasarkan hasil pengujian dengan menggunakan metode *LBP*, parameter radius untuk akurasi terbaik adalah 7. Ini disebabkan karena :

1. Nilai-nilai fitur histogram yang dihasilkan oleh *LBP* radius 7 dapat memisahkan kelas satu dengan yang lain dengan lebih baik dibandingkan radius yang lain.
2. Tekstur wajah yang dihasilkan *LBP* radius 7 secara tidak langsung mengambil wajah pada bagian-bagian inti wajah seperti mata dan mulut. Ini dikarenakan piksel-piksel pada bagian bawah dan kanan dari citra wajah menjadi gelap disebabkan oleh nilai ketetanggaan yang diperoleh pada bagian kanan dan bawah titik pusat akan bernilai 0 karena melebihi indeks piksel maksimal.

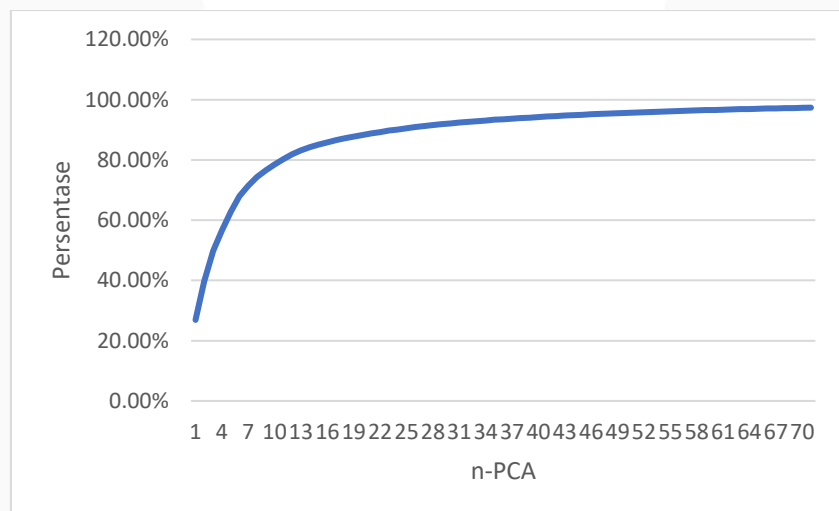


Gambar 4.6 Tektur Wajah pada *LBP* Radius 7

Rata-rata akurasi paling tinggi pada nilai $k=1$ menunjukkan bahwa persebaran data-data fitur tidak terlalu jauh, sehingga menambahkan nilai k akan menurunkan akurasi.

4.3.2 Metode *LBP+PCA*

Berdasarkan akurasi yang dihasilkan kombinasi metode *LBP* dan *PCA*, parameter n -First Principal Component untuk akurasi terbaik adalah 14 dengan akurasi 94.98% pada $k=3$. Pada n -First Principal Component 14, nilai total eigen value dari komponen 1 sampai dengan 14 adalah 85.11%, cukup untuk mewakili seluruh fitur yang ada.




Gambar 4.7 Grafik Nilai Eigenvalues

Mengkombinasikan metode *LBP* dengan *PCA* akan meningkatkan akurasi klasifikasi pada beberapa nilai n -First Principal Component lebih dari 13. Ini disebabkan fitur-fitur yang dikeluarkan *LBP* diproeksikan pada ruang vektor yang baru sehingga nilai-nilai pada fitur-fitur yang cenderung memiliki variansi rendah (berdekatan) menjadi lebih berjauhan sehingga lebih mudah untuk diklasifikasi.


Kombinasi dengan Metode *PCA* juga meningkatkan kecepatan klasifikasi pada nilai n -First Principal Component kurang dari 64 karena fitur-fitur yang diproses pada saat klasifikasi lebih sedikit. Namun proses klasifikasi akan memakan waktu lebih lama jika menggunakan n -First Principal Component lebih dari 64, dikarenakan walaupun fitur yang diproses lebih sedikit, komputasi perhitungan jarak tetangga pada klasifier KNN dengan metode *LBP+PCA* mengoperasikan tipe data float, sedangkan pada metode *LBP* mengoperasikan tipe data integer.

Rata-rata akurasi semua n -First Principal Component pada masing-masing k memiliki nilai paling tinggi pada $k=3$, disebabkan persebaran data sudah berubah menjadi lebih jauh dari sebelumnya (fitur *LBP*) karena diprojektikan pada ruang vector *PCA*.

4.3.3 Kesalahan Rekognisi



Gambar 4.8 Grafik Perbandingan Fitur *LBP* “Irfan” dengan “Ari”



Gambar 4.9 Grafik Perbandingan Fitur *PCA* “Irfan” dengan “Ari”

Sebagian besar wajah yang salah dikenali adalah wajah dengan label “Irfan”, dikenali sebagai wajah dengan label “Ari”. Berdasarkan perbandingan fitur-fitur yang dimiliki 2 kelas tersebut, terlihat bahwa nilai fitur *LBP* dan *PCA* pada dua kelas tersebut tidak terlalu berbeda. Ini membuktikan dengan menggunakan metode *LBP* dan *PCA* masih belum dapat memisahkan kelas “Irfan” dengan “Ari”.

5. Kesimpulan

Berdasarkan seluruh hasil pengujian dan analisis yang telah dilakukan pada penelitian ini, maka dapat ditarik kesimpulan :

1. Parameter radius *LBP* yang terbaik untuk citra wajah dengan resolusi rendah 35x35 piksel adalah 7
2. Parameter n-First Principal Component yang terbaik untuk mengekstrak fitur *LBP* adalah pada $n = 14$
3. Mengkombinasikan metode *LBP* dengan *PCA* dapat meningkatkan akurasi dibandingkan dengan tidak menggunakan *PCA*, pada beberapa parameter n-First Principal Component lebih dari 13, dengan titik akurasi tertinggi 94.98%.