

Pengaruh Teknik *Scanning* pada Proyeksi *Random Sparse Representation based Classification* untuk Pengenalan Wajah

Ivy Anindhita Hadyningtyas^{1*}, Denta Rahmadani², Koredianto Usman³,
Susmini Indriani Lestaringati⁴

^{1,2,3)} Program Studi Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom
Jl. Telekomunikasi No. 1, Kabupaten Bandung, Jawa Barat 40257

⁴⁾ Program Studi Teknik Komputer, Fakultas Teknik dan Ilmu Komputer, Universitas Komputer Indonesia
Jl. Dipatiukur no. 112 – 116, Bandung, Jawa Barat 40132
*email: ivyanindhita@student.telkomuniversity.ac.id

(Naskah masuk: 30 Mei 2022; diterima untuk diterbitkan: 03 Juli 2022)

ABSTRAK – *Sparse Representation based Classification* (SRC) merupakan metode yang cukup handal dalam melakukan klasifikasi pada pengenalan wajah. Namun teknik ini masih terdapat kekurangan yaitu beban komputasi yang tinggi serta dibutuhkannya data latih yang besar untuk memenuhi kondisi *sparse*. Salah satu teknik untuk menurunkan beban komputasi adalah melakukan penurunan dimensi citra. Pada metoda SRC terdapat matriks A yang dihasilkan dari kumpulan citra latih. Untuk dapat membentuk matriks tersebut diperlukan teknik untuk mengubah dimensi citra dari matriks dua dimensi menjadi satu dimensi yang disebut dengan teknik *scanning*. Terdapat tiga teknik *scanning* yang dapat dilakukan yaitu kolom ke baris, baris ke kolom dan zigzag. Pada makalah ini disimulasikan ketiga teknik *scanning* tersebut dan melihat pengaruhnya terhadap akurasi dan waktu komputasi. Pengujian dilakukan dengan menggunakan dataset AT&T dengan menggunakan rasio 50:50 untuk citra latih dan citra uji. Pengujian penurunan dimensi menggunakan distribusi acak, dan tiga teknik *scanning*. Dari hasil pengujian didapatkan hasil distribusi acak Uniform Interger dengan nilai akurasi sebesar 100% pada faktor reduksi sebesar 128. Dari masing-masing distribusi didapatkan penurunan akurasi dan waktu komputasi seiring dengan nilai faktor reduksi yang semakin tinggi. Pengujian ketiga teknik *scanning* didapatkan hasil akurasi yang sama, namun waktu komputasi teknik zigzag lebih cepat 1% dibandingkan dibandingkan lainnya.

Kata Kunci – *Proyeksi acak, Pengenalan wajah, Scanning, SRC.*

Effect of Scanning Technique on Random Projection Sparse Representation based Classification Algorithm for Face Recognition

ABSTRACT – *Sparse Representation based Classification* (SRC) is a reliable method for classifying facial recognition. However, this technique still has drawbacks, namely a high computational load and the need for large training data to meet sparse conditions. One technique to reduce the computational load is to reduce the dimensions of the image. In the SRC method there is a matrix A generated from a collection of training images. To be able to form the matrix, a technique is needed to change the image dimensions from a two-dimensional matrix into one dimension, which is called a scanning technique. There are three scanning techniques that can be done, namely column to row, row to column and zigzag. In this paper, the three scanning techniques are simulated and see their effect on accuracy and computation time. Tests were carried out using the AT&T dataset using a 50:50 ratio for the training image and the test image. The dimension reduction test uses a random distribution, and three scanning techniques. From the test results, it was obtained that the Uniform Interger random distribution with an accuracy value of 100% at a reduction factor of 128. From each distribution, it was found that the accuracy and computation time decreased along with the higher the value of the reduction factor. Tests of the three scanning techniques obtained the same accuracy results, but the computation time of the zigzag technique was 1% faster than the others.

Keywords – *Face recognition, Random projection, Scanning, SRC.*

1. PENDAHULUAN

Pengenalan wajah merupakan teknologi yang mampu untuk mengidentifikasi seseorang baik dari gambar digital maupun sumber video [1]. Sistem pengenalan wajah dapat digunakan dalam beberapa aplikasi dalam bidang seperti kontrol akses [2], absensi [3],[4], keamanan [5],[6], dan lain-lain. Meskipun demikian pada proses pengenalan wajah terdapat beberapa permasalahan seperti pencahayaan (iluminasi), ekspresi wajah, variasi pose, penggunaan properti pada wajah atau disebut dengan variasi oklusi, dan lain-lain [7]. Selain daripada itu masih terdapat masalah lain yaitu masalah ukuran citra yang besar, yang dapat membebani komputasi.

Pengenalan wajah memiliki dua tahapan yaitu: ekstraksi fitur dan klasifikasi. Ekstraksi fitur digunakan untuk mengambil ciri-ciri penting dari sebuah wajah. Oleh karena itu pemilihan ekstraksi fitur dapat mempengaruhi tingkat akurasi dalam pengenalan wajah [8]. Terdapat beberapa jenis ekstraksi fitur yang telah ada antara lain: ekstraksi tekstur, ukuran, bentuk, warna, dan geometri [9].

Setelah proses ekstraksi fitur, tahapan selanjutnya yaitu adalah proses klasifikasi. Klasifikasi merupakan tahapan untuk mengetahui kelas yang tepat dimana citra uji berada didalam kumpulan citra latih. Beberapa metoda klasifikasi yang telah dikembangkan oleh peneliti seperti, *Nearest Neighbour* (NN), *Support Vector Machine* (SVM), *Sparse Representation based Classification* (SRC), dan lain-lain. Klasifikasi NN memiliki beberapa kelebihan salah satunya algoritma NN melakukan klasifikasi berdasarkan data pembelajaran yang diambil dari data tetangga terdekatnya. Klasifikasi NN menunjukkan bahwa NN menurunkan kinerja pengenalan wajah karena *outlier* atau *noise* [10]. Sedangkan untuk kelemahan dari SVM yaitu sulit digunakan pada jumlah sampel dengan skala besar. Metoda pengenalan wajah dengan menggunakan teknik representasi *sparse* yang diusulkan pada tahun 2009 oleh John Wright. dkk [10] yang dinamakan *Sparse Representation based Classification* (SRC). Ide utama dari algoritma SRC adalah bahwa sebuah citra uji dapat direpresentasikan secara linier oleh sampel lain dari kelas yang sama, disisi lain kelas yang berbeda bebas linier. Citra latih yang digunakan adalah sekumpulan gambar wajah yang diambil dari beberapa individu yang berbeda yang diubah ke sebuah matriks $\mathbf{A} \in \mathbf{R}^{m \times n}$, dengan w mewakili lebar dan h mewakili tinggi [11]. Versi vektor dari matriks \mathbf{A} dapat ditulis dengan $\mathbf{v} \in \mathbf{R}^m$ dengan $m = w \times h$ yang merepresentasikan sebuah citra wajah pada data latih [12]. Teknik SRC dapat dikatakan sudah cukup baik dalam mengenali citra uji bahkan citra yang memiliki oklusi sebesar 40%, variasi pose, dan

berbagai macam ekspresi wajah, bahkan telah dapat mengenali citra korup hingga 70% [10]. Walaupun demikian, teknik ini masih terbebani dengan komputasi yang tinggi didalam menghitung minimisasi- ℓ_1 , serta diperlukan database yang besar untuk memenuhi kondisi *sparse*. Hingga saat ini banyak peneliti yang terus mengembangkan metoda SRC ini, dengan tujuan yaitu untuk menurunkan beban komputasi, mengatasi masalah jumlah data yang sedikit atau disebut dengan istilah *undersample data* serta menaikkan tingkat akurasi. Pada tahun 2009 [13] mengusulkan untuk menurunkan waktu kompleksitas dengan cara meningkatkan efisiensi perhitungan. Metode pengenalan wajah yang disebut klasifikasi berbasis representasi jarang pada subruang k - terdekat atau *Sparse Representation based Classification K-Nearest Subspace* (SRC-KNS). Pada tahun 2012 [14] mengusulkan teknik untuk mengatasi jumlah citra latih yang terbatas dengan melakukan ekstensi terhadap SRC. Teknik yang diusulkan menerapkan kamus varian intra kelas tambahan untuk mewakili variasi yang mungkin antara citra latih dengan citra uji. Nilai kamus atom akan mewakili perbedaan sampel intra kelas yang dihitung dari data wajah sendiri atau wajah yang didapatkan dari luar kamus dan bersifat umum. Pada tahun 2013 [15] mengusulkan algoritma untuk minimisasi orde satu yang lebih cepat untuk menurunkan waktu komputasi.

Salah satu metoda yang digunakan untuk menurunkan beban komputasi adalah dengan cara menurunkan ukuran dimensi dari citra dari ruang dimensi \mathbf{R}^m kedalam \mathbf{R}^d ($d \ll m$). Menurut Wright, penurunan dimensi dapat dilakukan dengan menggunakan suatu proyeksi acak /*random* [10]. Secara praktis, SRC juga harus memenuhi syarat *underdetermined*. Penggunaan proyeksi acak dikarenakan proses perhitungannya yang sederhana dibandingkan dengan teknik lain yang menggunakan transformasi yang lebih kompleks [12].

Sebelum proses pembentukan matriks $\mathbf{A} \in \mathbf{R}^{M \times N}$, diperlukan perubahan perubahan dari matriks dua dimensi menjadi vektor satu dimensi yang disebut dengan teknik *scanning*. Teknik *scanning* ini dapat dilakukan dengan cara mengurutkan dari baris ke kolom, kolom ke baris [16], dan zigzag [17]. Dalam upaya meningkatkan tingkat akurasi, pada makalah ini akan disimulasikan penggunaan dari ketiga metoda *scanning*, serta melihat pengaruhnya dalam tingkat akurasi dan waktu komputasi. Penurunan dimensi yang digunakan pada makalah ini adalah menggunakan proyeksi acak dengan distribusi Gaussian, Uniform Biner dan Uniform Interger.

2. METODE PENELITIAN

2.1 Algoritma Sparse Representation based Classification (SRC)

Terdapat sejumlah citra yang membentuk Kamus \mathbf{A} yang disusun menjadi $\mathbf{A} = [A_1, A_2, \dots, A_k] \in \mathbf{R}^{m \times n}$ dengan n adalah dimensi dari setiap sampel, n merupakan jumlah sampel, dan k adalah jumlah kelas [18]. Maka representasi linier dari \mathbf{y} dapat ditulis sebagai sampel latihan Persamaan (1) berikut [10]:

$$\mathbf{y} = \mathbf{A}\mathbf{x} \in \mathbf{R}^m \quad (1)$$

Penyelesaian masalah untuk menemukan representasi *sparse* \mathbf{x} , dapat menggunakan solusi minimisasi- ℓ_0 Persamaan (2) berikut [10]:

$$\hat{\mathbf{x}}_0 = \arg \min_x \|\mathbf{x}\|_0 \quad \text{untuk } \mathbf{A}\mathbf{x} = \mathbf{y} \quad (2)$$

Namun, masalah untuk menemukan solusi representasi yang paling jarang dari sistem persamaan linier yang *underdetermined* sulit untuk didekati dan *NP-hard*. Jika solusi \mathbf{x}_0 yang dicari cukup *sparse*, maka solusi dari masalah minimisasi- ℓ_0 Persamaan (2) sama dengan solusi untuk masalah minimisasi- ℓ_1 Persamaan (3) berikut [10]:

$$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1 \quad \text{untuk } \mathbf{A}\mathbf{x} = \mathbf{y} \quad (3)$$

Peneliti telah mengasumsikan bahwa Persamaan (3) tepat, maka model Persamaan (3) dapat dimodifikasi secara eksplisit dengan memperhitungkan *noise* yang terdapat pada data real berikut [10]:

$$\mathbf{y} = \mathbf{A}\mathbf{x} + \mathbf{z} \quad (4)$$

Dimana, $\mathbf{z} \in \mathbf{R}^m$ adalah *noise* dengan energi terbatas $\|\mathbf{z}\|_2 < \epsilon$. Maka solusi *sparse* \mathbf{x}_0 bisa dipulihkan dengan menyelesaikan minimisasi- ℓ_1 berikut [10]:

$$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1 \quad \text{untuk } \|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2 \leq \epsilon \quad (5)$$

Algoritma SRC dapat diturunkan sebagai berikut [10]:

Algoritma 1 Algoritma SRC

Input: matriks sampel latihan

$\mathbf{A} = [A_1, A_2, \dots, A_k] \in \mathbf{R}^{m \times n}$ untuk sejumlah k kelas

Dengan sampel uji $\mathbf{y} \in \mathbf{R}^m$ (toleransi error $\epsilon > 0$)

Output: kelas $(\gamma) = \arg \min_x r_i(\gamma)$

Normalisasi kolom \mathbf{A} untuk mendapatkan unit normalisasi- ℓ_2

Menyelesaikan masalah minimisasi- ℓ_1 :

$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1$ untuk $\mathbf{A}\mathbf{x} = \mathbf{y}$

(atau dengan alternatif lain)

$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1$ untuk $\|\mathbf{A}\mathbf{x} - \mathbf{y}\|_2 \leq \epsilon$

Cari residual:

$r_i(\gamma) = \|\mathbf{y} - \mathbf{A}\alpha_i(\hat{\mathbf{x}}_1)\|_2$ untuk $i = 1, 2, \dots, n$

2.2 Algoritma Proyeksi Acak SRC

Menurut Candes. dkk [19], matriks dari proyeksi acak harus memenuhi syarat *Restricted Isometric*

Property (RIP), untuk memulihkan data. Beberapa distribusi acak memenuhi RIP, yaitu distribusi acak Gaussian dan Uniform. Kedua distribusi tersebut digunakan dalam penelitian ini. Karena dimensi dari matriks \mathbf{A} besar, maka diperlukannya proses penurunan dimensi pada citra. Proyeksi acak dapat diterapkan untuk meningkatkan efisiensi komputasi sambil menjaga akurasi pengenalan [17]. Proyeksi acak dalam penurunan dimensi matriks \mathbf{y} dan matriks \mathbf{A} dengan cara mengalikan matriks dengan dengan proyeksi acak Φ yang lebih kecil dari ukuran matriks \mathbf{A} . Kemudian penurunan dimensi dengan matriks proyeksi acak Φ berubah dari \mathbf{R}^m menjadi \mathbf{R}^d sesuai dengan Persamaan (7), Persamaan (8), dan Persamaan (9) [11].

$$\gamma = \Phi \mathbf{y} \in \mathbf{R}^d \quad (7)$$

$$\mathbf{x} = \Phi \mathbf{A} \in \mathbf{R}^d \quad (8)$$

$$\gamma = \mathbf{x}\mathbf{x} \in \mathbf{R}^d \quad (9)$$

Secara umum algoritma proyeksi acak SRC dapat diturunkan sebagai berikut [11]:

Algoritma 2 Algoritma Proyeksi acak SRC

Input: matriks sampel latihan

$\mathbf{A} = [A_1, A_2, \dots, A_k] \in \mathbf{R}^{m \times n}$ untuk sejumlah k kelas

Dengan sampel uji $\gamma \in \mathbf{R}^m$ (toleransi error $\epsilon > 0$)

Output: kelas $(\gamma) = \arg \min_x r_i(\gamma)$

Normalisasi kolom \mathbf{A} untuk mendapatkan unit normalisasi- ℓ_2

Menyelesaikan masalah minimisasi- ℓ_1 :

$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1$ untuk $\Phi \mathbf{A}\mathbf{x} = \gamma$

(atau dengan alternatif lain)

$\hat{\mathbf{x}}_1 = \arg \min_x \|\mathbf{x}\|_1$ untuk $\|\Phi \mathbf{A}\mathbf{x} - \gamma\|_2 \leq \epsilon$

Cari residual:


$r_i(\gamma) = \|\gamma - \Phi \mathbf{A}\alpha_i(\hat{\mathbf{x}}_1)\|_2$ untuk $i = 1, 2, \dots, n$

Dari penelitian [10] mengatakan bahwa optimasi ini berkinerja baik dalam masalah oklusi. Oklusi merupakan gangguan citra wajah dengan adanya penutup seperti masker, cadar, dan lain-lain. Untuk oklusi yang mencakupi 40% dari wajah dan 70% oklusi pada gambar, metode ini dapat mengenali dengan baik tanpa kesalahan. Ada beberapa metode terkenal untuk memecahkan masalah minimisasi- ℓ_1 , penelitian ini menggunakan algoritma *Least Absolute Shrinkage and Selection Operator* (Lasso), karena metode ini dapat mengecilkan koefisien regresi yang memiliki korelasi yang tinggi menjadi tepat nol atau mendekati nol.

2.3 Teknik Scanning


Sampel citra pada proses pengenalan wajah dibagi menjadi dua yaitu sampel uji dan sampel latihan. Kedua sampel tersebut merupakan citra dua dimensi

yang kemudian diubah menjadi suatu vektor satu dimensi yang akan membentuk sebuah matriks **A**, contoh matriks **A** dapat dilihat pada Gambar 1.




Gambar 1. Pembentukan Matriks A


Pada Gambar 1. dengan citra awal diambil dari individu yang sama namun dengan pose yang berbeda yang disebut sebagai citra dua dimensi, yang kemudian diubah menjadi vektor satu dimensi pada bagian kanan dan membentuk sebuah matriks **A**. Pengubahan citra tersebut dapat dilakukan dengan tiga teknik *scanning*, yaitu teknik *scanning* kolom ke baris, baris ke kolom, dan *zigzag*. Teknik *scanning* kolom ke baris dapat diilustrasikan seperti pada Gambar 2, teknik *scanning* baris ke kolom diilustrasikan seperti pada Gambar 3, dan teknik *scanning zigzag* diilustrasikan seperti pada Gambar 4.



Gambar 2. Teknik *Scanning* Kolom ke Baris



Gambar 3. Teknik *Scanning* Baris ke Kolom



Gambar 4. Teknik *Scanning* Zigzag

2.4 Parameter Kinerja Sistem

Parameter dari kinerja sistem yang digunakan dalam penelitian ini adalah.

1. Faktor Reduksi

Faktor reduksi merupakan rasio perbandingan antara ukuran dimensi citra awal dengan ukuran hasil reduksi. Persamaan (10) merupakan persamaan yang digunakan untuk menghasilkan nilai faktor reduksi [11].

$$\text{Faktor reduksi } (\rho) = \frac{\text{Ukuran citra awal } (m)}{\text{Ukuran citra hasil reduksi } (d)} \quad (10)$$

2. Tingkat Akurasi

Tingkat akurasi dilihat dari ketepatan dalam mengenali citra, di bandingkan dengan jumlah total citra uji pada setiap teknik penurunan dimensi dan teknik *scanning* yang dilakukan. Persamaan (11) merupakan rumus yang digunakan dalam mencari akurasi.

$$\text{Akurasi} = \frac{T}{N} \times 100\% \quad (11)$$

Keterangan: T = citra dikenali, N = total citra uji.

3. Waktu Komputasi

Waktu komputasi diperoleh dengan cara mengurangi waktu saat selesai dengan waktu saat mulai. Persamaan (12) merupakan rumus waktu komputasi.

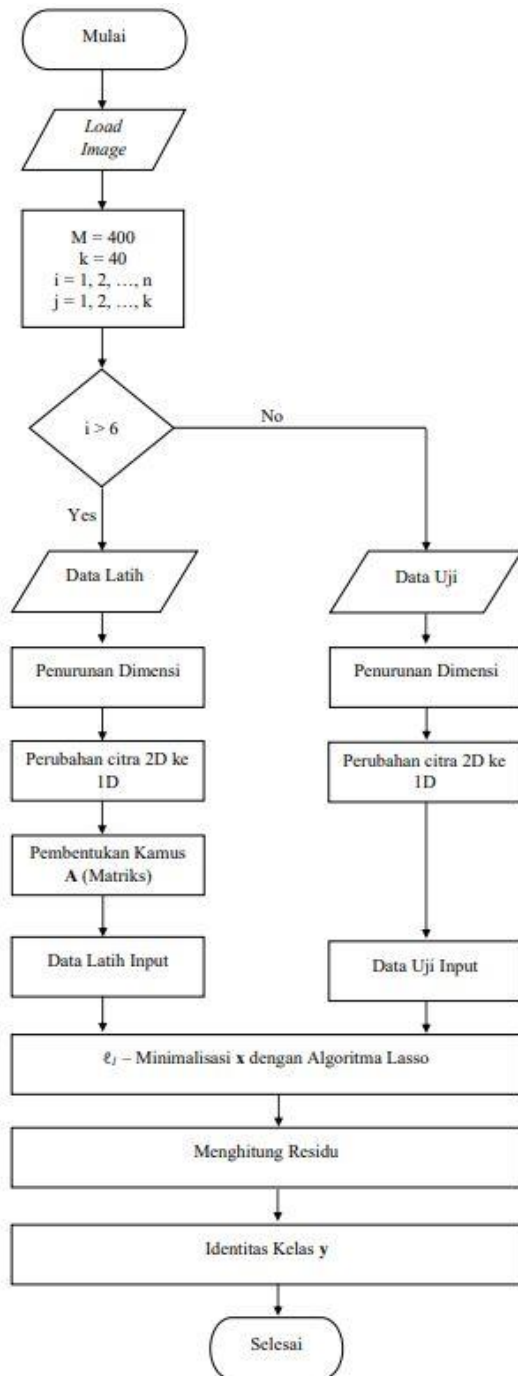
$$W_k = W_s - W_m \quad (12)$$

Keterangan: W_k = waktu komputasi, W_s = waktu selesai, dan W_m = waktu mulai.

2.5 Diagram Alir Sistem

Proses dimulai dari membaca citra database. Citra database terdiri dari 400 citra (i) dengan masing-masing citra uji dan citra latih sebanyak 200 citra dan terdiri dari 40 kelas (j). Apabila $i > 6$, maka citra dinyatakan sebagai citra latih, sedangkan apabila $i < 6$ maka citra dinyatakan sebagai citra uji. Citra yang telah dibagi tersebut, dilanjutkan dengan proses penurunan dimensi yang menggunakan proyeksi acak dan teknik linier sederhana yaitu *downscale*. Setelah dilakukan penurunan dimensi, selanjutnya dilakukan proses citra 2D ke 1D yang menggunakan tiga teknik *scanning*, yaitu kolom ke baris, baris ke kolom, dan *zigzag* yang kemudian membentuk sebuah kamus matriks **A**. Proses pembentukan kamus **A** tersebut hanya dilakukan untuk citra latih. Kemudian citra asli tersebut telah berubah menjadi vektor satu dimensi. Setelah memperoleh matriks **A**, proses dilanjutkan dengan mencari x dengan melakukan minimisasi- ℓ_1 menggunakan algoritma Lasso. Nilai residu yang

terendah menunjukkan bahwa kelas dari y (citra uji) berada. Berikut Gambar (5) merupakan diagram alir yang digunakan pada penelitian ini.



Gambar 5. Diagram Alir Sistem

3. HASIL DAN PEMBAHASAN

Parameter yang akan dilihat adalah tingkat akurasi dan waktu komputasi. Simulasi ini dijalankan pada sistem operasi Windows 10 Home 64-bit, Processor Intel(R) Core (TM) i7-8550U CPU @ 1.80GHz (8 CPUs) 2.0 GHz, dan Memori 8192 RAM.

Simulasi ini menggunakan dataset wajah yang populer seperti AT&T. Dataset yang digunakan

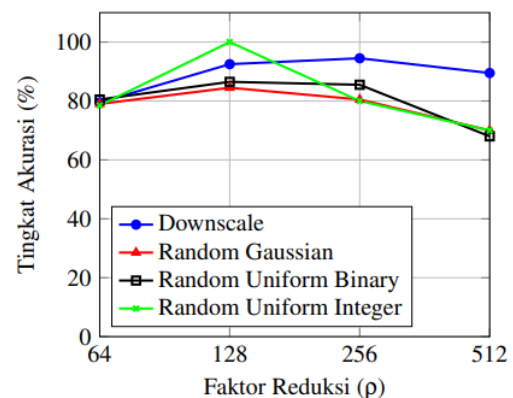
adalah 200 citra latih dan 200 citra uji dari 40 kelas. Gambar yang tersedia memiliki pencahayaan yang berbeda, ekspresi wajah, dan detail wajah yang berbeda.

Pengujian dilakukan dengan penurunan faktor reduksi (ρ) mulai dari 64 sampai 512. Parameter yang diuji adalah waktu komputasi dan tingkat akurasi. Hasil pengujian ditunjukkan pada Tabel 1 dan Tabel 2 dengan menggunakan teknik *scanning* kolom ke baris.

Pada Tabel 1 menunjukkan bahwa hasil penurunan dimensi mempengaruhi tingkat akurasi, dimana tingkat akurasi menurun seiring dengan penurunan dimensi. Tingkat pengenalan dari *downscale* SRC menurun secara linier dengan penurunan dimensi dari 89,5% sampai dengan 79,5%, dengan nilai maksimum dihasilkan dari faktor reduksi 256 sebesar 94,5%. Hasil dari tingkat pengenalan proyeksi acak tergantung dari matriks acak yang dihasilkan pada proses pengujian. Akurasi dari pengujian proyeksi acak berkisar dari nilai maksimum sebesar 100% dan nilai minimum sebesar 68%. Dimensi meningkat dari faktor reduksi 64 hingga 256, kemudian kinerja dari tingkat akurasi turun setelahnya yaitu saat faktor reduksi 512. Hasil proyeksi acak diperoleh secara berulang, dikarenakan untuk mencari matriks proyeksi acak yang terbaik dan diupayakan memiliki hasil kinerja terbaik dengan iterasi berulang. Berikut Tabel 1 dan Gambar 6 menunjukkan tingkat akurasi terhadap faktor reduksi.

Tabel 1. Tingkat Akurasi Maksimum Terhadap Faktor Reduksi

Faktor Reduksi (ρ)	Tingkat Akurasi (%)			
	Downscale	Random Gaussian	Random Uniform Binary	Random Uniform Integers
64	79,5	79	80,5	78,5
128	92,5	84,5	86,5	100
256	94,5	80,5	85,5	80
512	89,5	70	68	70



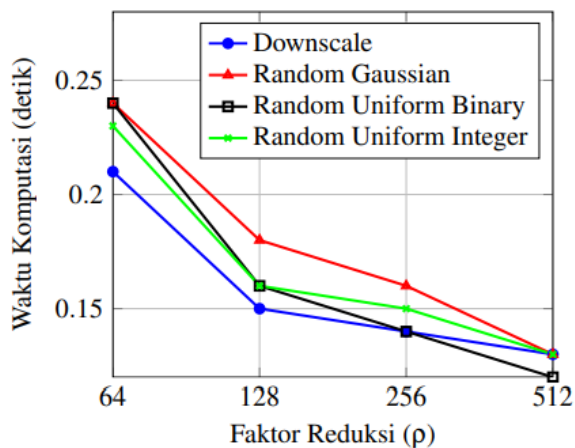
Gambar 6. Tingkat Akurasi Maksimum dari Proyeksi Acak dan *Downscale*

Selanjutnya dari sisi waktu komputasi, sesuai pada Tabel 2 terlihat bahwa semakin besar nilai dari ρ , maka semakin cepat waktu komputasi berjalan, tetapi semakin besar ρ tingkat akurasi yang dihasilkan semakin kecil. Hasil dari waktu pemrosesan dapat membantu mempertimbangkan penerapan pengukuran dimensi. Berikut Tabel 2 merupakan hasil dari waktu komputasi terhadap faktor reduksi.

Tabel 2 Waktu Komputasi Terhadap Faktor Reduksi

Faktor Reduksi (ρ)	Waktu Komputasi (detik)			
	Downscale	Random Gaussian	Random Uniform Binary	Random Uniform Integers
64	0,21	0,24	0,24	0,23
128	0,15	0,17	0,16	0,16
256	0,14	0,15	0,14	0,15
512	0,13	0,13	0,13	0,13

Gambar 7 menunjukkan hasil dari simulasi waktu komputasi terhadap faktor reduksi.



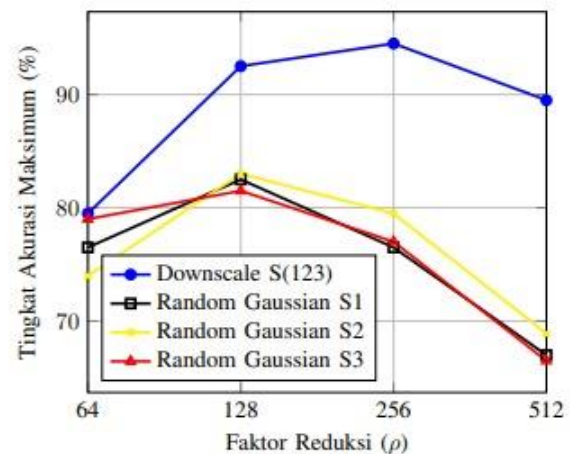
Gambar 7. Penurunan Dimensi dari Waktu Komputasi

Skenario berikutnya adalah pengujian pengaruh dari teknik *scanning* yang digunakan pada saat pembentukan matriks **A** terhadap hasil akurasi dan waktu komputasi yang diperlukan. Teknik *scanning* yang diujikan antara lain teknik *scanning* 1 yaitu kolom ke baris, teknik *scanning* 2 yaitu baris ke kolom, dan teknik *scanning* 3 yaitu *zigzag*. Tabel 4 merupakan hasil dari tingkat akurasi yang dilakukan pengujian untuk *downscale* dan Random Gaussian pada setiap teknik *scanning*.

Tabel 3 Tingkat Akurasi dengan Menggunakan Teknik *Scanning* Kolom ke Baris (S1), Baris ke Kolom (S2) dan *Zigzag* (S3)

Faktor Reduksi (ρ)	Tingkat Akurasi (%)					
	Downscale			Random Gaussian		
	S1	S2	S3	S1	S2	S3
64	79,5	79,5	79,5	76,5	74	79
128	92,5	92,5	92,5	82,5	83	81,5
256	94,5	94,5	94,5	76,5	79,5	77
512	89,5	89,5	89,5	82,5	80	83

Pada Tabel 3 dapat dilihat bahwa teknik *scanning* tidak mempengaruhi hasil dari tingkat akurasi pada pengujian *downscale* dengan menampilkan nilai yang sama pada teknik *scanning* yang digunakan, yang memiliki tingkat akurasi tertinggi 94,5% pada faktor reduksi 256. Sedangkan ketika dilakukan pengujian proyeksi acak Gaussian didapat hasil dengan nilai akurasi tertinggi 83% menggunakan teknik *scanning* 3 dengan faktor reduksi 512. Tingkat akurasi digambarkan pada Gambar 8.



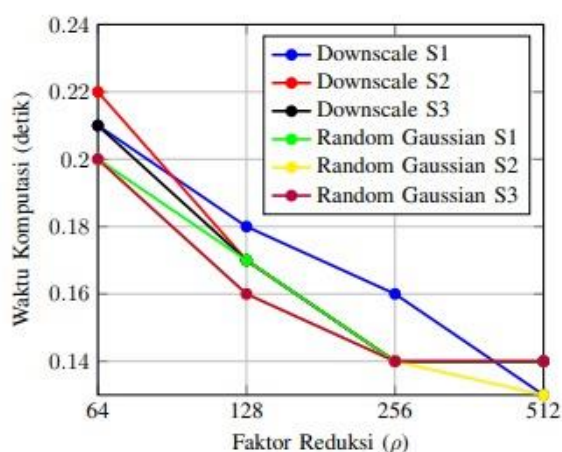
Gambar 8. Pengujian Waktu Komputasi pada Teknik *Scanning* terhadap Faktor Reduksi

Waktu komputasi yang dihasilkan dari percobaan dapat dilihat pada Tabel 4.

Tabel 4 Waktu Komputasi Metoda SRC Menggunakan Teknik *Scanning* Kolom ke Baris (S1), Baris ke Kolom (S2) dan *Zigzag* (S3)

Faktor Reduksi (ρ)	Waktu Komputasi (detik)					
	Downscale			Random Gaussian		
	S1	S2	S3	S1	S2	S3
64	0,21	0,22	0,21	0,20	0,20	0,20
128	0,18	0,17	0,17	0,17	0,16	0,16
256	0,16	0,14	0,14	0,14	0,14	0,14
512	0,13	0,14	0,14	0,14	0,13	0,12

Waktu komputasi yang dihasilkan tidak terlalu berbeda dari setiap teknik *scanning* yang dipilih. Waktu komputasi tertinggi terdapat pada saat pengujian *downscale* yaitu 0,22 detik dengan menggunakan *scanning* 2 pada $\rho = 64$. Sedangkan waktu komputasi paling cepat terdapat pada pengujian Random Gaussian dengan waktu sebesar 0,12 detik menggunakan S3 pada $\rho = 512$. Dari tabel tersebut dapat disimpulkan bahwa faktor reduksi sangat mempengaruhi cepat atau lambatnya waktu komputasi yang diperlukan. Waktu komputasi yang dihasilkan pada setiap teknik *scanning* dapat digambarkan pada Gambar 9.



Gambar 9. Pengujian Waktu Komputasi pada Ketiga Teknik *Scanning* terhadap Faktor Reduksi

4. KESIMPULAN

Berdasarkan hasil penelitian yang dilakukan mengenai pengaruh proyeksi acak dan teknik *scanning* pada algoritma SRC untuk pengenalan wajah maka dapat disimpulkan bahwa matriks proyeksi acak dapat mempertahankan kinerja dari pengenalan wajah saat penurunan dimensi dilakukan. Faktor reduksi dengan nilai 128 memiliki tingkat akurasi yang terbaik pada teknik proyeksi acak uniform integer yaitu sebesar 100% dengan waktu komputasi 0,16 detik. Sedangkan untuk nilai dari tingkat akurasi *downscale* terdapat pada faktor reduksi sebesar 256 dengan tingkat akurasi sebesar 94,5% dan waktu komputasi 0,14 detik. Matriks proyeksi acak harus diperoleh secara berulang hingga didapatkan nilai akurasi tertinggi. Dari waktu komputasi yang dihasilkan akan berbeda sesuai dengan kinerja komputer yang digunakan.

Selain itu, Penggunaan dari teknik *scanning* yang berbeda (kolom ke baris, baris ke kolom, *zigzag*) tidak mempengaruhi hasil akurasi dari pengenalan wajah ketika *downscale* dengan tingkat akurasi tertinggi yang diperoleh sebesar 94,5% pada ketika teknik *scanning*. Namun ketika dilakukan dengan menggunakan random gaussian akan didapatkan hasil yang berbeda untuk setiap teknik *scanning* yang

digunakan, tingkat akurasi terbesar yang diperoleh sebesar 83% pada saat faktor reduksi 128 menggunakan teknik *scanning* kedua dan 83% pada saat faktor reduksi 128 menggunakan teknik *scanning* ketiga hal tersebut dikarenakan saat dipilih Random Gaussian maka pengenalan wajah dilakukan secara acak. Waktu komputasi tertinggi terdapat pada pengujian *downscale* yaitu 0,22 detik dengan menggunakan teknik S2.

Untuk penelitian lebih lanjut, dapat diteliti terkait penggunaan oklusi menggunakan properti tambahan seperti cadar atau masker. Selain itu, penelitian dapat dilanjutkan dengan menggunakan citra wajah dari orang Indonesia.

DAFTAR PUSTAKA

- [1] S. Kovacevic, V. Djaletic, and J. Vukovic, "Face Recognition using Compressive Sensing," pp. 1-4, 2019, [Online]. *The 8th Mediterranean Conference on Embedded Computing*, Available: <http://arxiv.org/abs/1902.05388>.
- [2] P. Nurmala, W. Gazali, and W. Budiharto, "Sistem Kontrol Akses Berbasis Real Time Face Recognition dan Gender Information," *ComTech Comput. Math. Eng. Appl.*, vol. 6, no. 2, p. 198, 2015, doi: 10.21512/comtech.v6i2.2264.
- [3] I. Jurjawi, "Implementasi Pengenalan Wajah Secara Real Time untuk Sistem Absensi Menggunakan Metode Pembelajaran Deep Learning Dengan Pustaka Open CV (Computer Vision)," *Int. J. Hypertens.*, vol. 1, no. 1, pp. 1-171, 2020.
- [4] P. U. Hadidtyo, S. Rahman, and S. Sundari, "Sistem Absensi Berbasis Pengenalan Wajah Secara Realtime Menggunakan Webcam Dengan Metode PCA (Principal Component Analysis) Eigenface dan Program Visual Studio," *Snastikom*, 2019.
- [5] V. S. Manjula and L. D. S. Santhosh Baboo, "Face Detection Identification and Tracking by PRDIT Algorithm using Image Database for Crime Investigation," *Int. J. Comput. Appl.*, vol. 38, no. 10, 2012, doi: 10.5120/4741-6649.
- [6] K. Lander, V. Bruce, and M. Bindemann, "Use-inspired basic research on individual differences in face identification: implications for criminal investigation and security," *Cogn. Res. Princ. Implic.*, vol. 3, no. 1, pp. 1-13, 2018, doi: 10.1186/s41235-018-0115-6.
- [7] M. Banitalebi-Dehkordi, A. Banitalebi-Dehkordi, J. Abouei, and K. N. Plataniotis, "Face recognition using a new compressive sensing-based feature extraction method," *Multimed. Tools Appl.*, vol. 77, no. 11, pp. 14007-14027, 2018, doi: 10.1007/s11042-017-5007-0.
- [8] A. Ciputra, D. R. I. M. Setiadi, E. H. Rachmawanto, and A. Susanto, "Klasifikasi

- Tingkat Kematangan Buah Apel Manalagi dengan Algoritma Naive Bayes dan Ekstraksi Fitur Citra Digital," *Simetris J. Tek. Mesin, Elektro dan Ilmu Komput.*, vol. 9, no. 1, 2018, doi: 10.24176/simet.v9i1.2000.
- [9] C. Suhery and I. Ruslianto, "Identifikasi Wajah Manusia untuk Sistem Monitoring Kehadiran Perkuliahan menggunakan Ekstraksi Fitur Principal Component Analysis (PCA)," *J. Edukasi dan Penelit. Inform.*, vol. 3, no. 1, p. 9, 2017, doi: 10.26418/jp.v3i1.19792.
- [10] J. Wright, S. Member, A. Y. Yang, A. Ganesh, S. Member, and S. S. Sastry, "via Sparse Representation," vol. 31, no. 2, pp. 210-227, 2009.
- [11] S. I. Lestaringati, A. B. Suksmono, K. Usman, and I. J. M. Edward, "Random Projection on Sparse Representation based Classification for Face Recognition," *2021 13th Int. Conf. Inf. Technol. Electr. Eng. ICITEE 2021*, pp. 171-176, 2021, doi: 10.1109/ICITEE53064.2021.9611825.
- [12] R. Ptucha and A. E. Savakis, "LGE-KSVD: Robust sparse representation classification," *IEEE Trans. Image Process.*, vol. 23, no. 4, 2014, doi: 10.1109/TIP.2014.2303648.
- [13] J. Yang, K. Yu, Y. Gong, and T. Huang, "Linear spatial pyramid matching using sparse coding for image classification," *2009 IEEE Conf. Comput. Vis. Pattern Recognition, CVPR 2009*, pp. 1794-1801, 2009, doi: 10.1109/CVPRW.2009.5206757.
- [14] W. Deng, J. Hu, and J. Guo, "Extended SRC: Undersampled face recognition via intraclass variant dictionary," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 34, no. 9, pp. 1864-1870, 2012, doi: 10.1109/TPAMI.2012.30.
- [15] A. Y. Yang, S. Member, Z. Zhou, A. G. Balasubramanian, S. S. Sastry, and Y. Ma, "Fast L1-Minimization Algorithms for Robust Face Recognition," vol. 22, no. 8, pp. 3234-3246, 2013.
- [16] K. Usman and M. Ramdhani, "Comparison of Classical Interpolation Methods and Compressive Sensing for Missing Data Reconstruction," *Proc. - 2019 IEEE Int. Conf. Signals Syst. ICSigSys 2019*, no. 2, pp. 29-33, 2019, doi: 10.1109/ICSIGSYS.2019.8811057.
- [17] M. H. Alkawaz, G. Sulong, T. Saba, and A. Rehman, "Detection of copy-move image forgery based on discrete cosine transform," *Neural Comput. Appl.*, vol. 30, no. 1, pp. 183-192, 2018, doi: 10.1007/s00521-016-2663-3.
- [18] V. R. Pamula, C. Van Hoof, and M. Verhelst, "Introduction to Compressive Sampling (CS)," *Analog Circuits Signal Process.*, no. March 2008, pp. 33-53, 2019, doi: 10.1007/978-3-030-05870-8_3.
- [19] E. J. Candès, "Compressive sampling," *Int. Congr. Math. ICM 2006*, vol. 3, pp. 1433-1452, 2006, doi: 10.4171/022-3/69.