



## Ekstraksi Fitur Daun dengan Penerapan Metode *Compressive Sensing*

Fellia Rizki Kusumowardani<sup>#1</sup>, Gelar Budiman<sup>#2</sup>, Sofia Saidah<sup>#3</sup>

<sup>#</sup>Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom  
Jalan Telekomunikasi No.1, Terusan Buah batu Bojongsoang 40257

<sup>1</sup>felliarizki@student.telkomuniversity.ac.id

<sup>2</sup>gelarbudiman@telkomuniversity.ac.id

<sup>3</sup>sofiasaidahsfi@telkomuniversity.ac.id

**Abstrak**— Daun menjadi salah satu daya tarik manusia untuk melakukan kegiatan berkebun atau kegiatan lain seperti penjualan tanaman karena dari segi bentuk daun yang unik dan karakteristik yang bermacam-macam. Untuk mengetahui karakteristik pada jenis daun dilakukan proses ekstraksi fitur. Tujuan dari ekstraksi fitur ini untuk mengetahui bentuk, tekstur, warna, ukuran, dan nilai yang digunakan sebagai pembeda antara satu objek dengan objek lain. Pada penelitian ini menggunakan 32 citra daun. Metode yang digunakan pada penelitian ini yaitu *Compressive Sensing* (CS), *Gray Level Co-Occurrence Matrix* (GLCM), dan *K-Nearest Neighbour* (K-NN). Hasil yang diperoleh menunjukkan kualitas dari kompresi ketika dilakukan pengujian dengan menggunakan rasio kompresi, MSE, PSNR, dan akurasi. Didapatkan hasil terbaik ketika menggunakan data latih bernilai 20, data uji bernilai 4, *block* bernilai 32, baris kompresi bernilai 32, dan *resize* berukuran  $512 \times 512$  menghasilkan rasio kompresi bernilai 3,1%, PSNR bernilai 22,1 dB, dan akurasi bernilai 100%.

**Kata kunci**— *Compressive Sensing* (CS), *Gray Level Co-Occurrence Matrix* (GLCM), *K-Nearest Neighbour* (K-NN), *Ekstraksi fitur daun*, PSNR

### I. PENDAHULUAN

Daun adalah bagian dari tanaman yang merupakan tumbuhan hidup yang dapat mengalami peralihan fungsi menjadi organ penyimpan air [1]. Daun juga menjadi daya tarik manusia untuk melakukan kegiatan berkebun atau kegiatan lain seperti penjualan tanaman karena dari segi bentuk daun yang unik dan karakteristiknya yang bermacam-macam. Beberapa jenis daun memiliki bentuk dan karakteristik yang hampir sama sehingga cukup sulit untuk membedakan satu jenis daun dengan daun lainnya. Untuk membantu manusia dalam membedakan jenis daun, maka pada penelitian ini dilakukan klasifikasi dari empat jenis daun. Pada Penelitian ini dilakukan ekstraksi fitur

pada daun untuk mengetahui bentuk, tekstur, warna, dan ukuran. Ekstraksi ciri digunakan untuk mendapatkan nilai yang dapat digunakan sebagai pembeda antara satu objek citra dengan objek lainnya sehingga dapat terlihat perbandingan perbedaan pada objek yang digunakan. Proses *Compressive Sensing* (CS) dengan mengumpulkan beberapa data lalu buang sebagian besar data dalam tahap kompresi untuk menghemat penyimpanan [2]. Tujuan penelitian ini adalah untuk mengetahui pengaruh CS pada sistem yang dirancang dalam melakukan klasifikasi jenis daun ditinjau dari parameter akurasi, PSNR nilai rasio kompresi. Pada penelitian [3] dilakukan klasifikasi jenis daun menggunakan metode *Gray Level Co-Occurrence Matrix* (GLCM) dan Jaringan Syaraf Tiruan (JST). Performansi sistem yang diperoleh diantaranya akurasi 98%, presisi 86% dan *recall* 86%. Pada penelitian ini dilakukan klasifikasi jenis daun menggunakan metode GLCM dan *K-Nearest Neighbour* (K-NN) dengan menerapkan CS untuk mengetahui apakah CS mempengaruhi hasil klasifikasi atau tidak. Metode CS memungkinkan proses rekonstruksi sinyal asli dari sebuah transformasi acak melalui proses optimasi [4]. GLCM mempunyai karakteristik tekstur yang diperoleh dari suatu citra sebagai pembeda antara citra dengan kelas tertentu seperti kontras, korelasi, homogenitas, dan energi. Kelebihan metode GLCM terdapat pada ciri statistiknya. GLCM menggunakan distribusi derajat keabuan yang berfungsi untuk menghitung tingkat kontras, granularitas, dan kekasaran suatu daerah dari hubungan ketetanggaan antar piksel di dalam citra [5]. Pada GLCM terdapat jarak dan sudut arah dengan empat periode yaitu  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$  dengan jarak antar piksel bernilai 1 [6]. Pada tahap terakhir terdapat proses klasifikasi dengan menggunakan metode *K-Nearest Neighbour* atau K-NN. Metode K-NN dapat melakukan training data dengan jumlah yang besar serta tahan terhadap noise [7]. Selain itu, penelitian [8] membuktikan bahwa metode *Gray Level Co-occurrence Matrix* (GLCM) mampu mendeteksi citra melalui ekstraksi fitur warna, tekstur dan bentuk

dengan nilai performansi sistem yang dihasilkan berupa *recall* 1 dan *precision* 0,44.

II. KAJIAN PUSTAKA

Citra Digital adalah proses pengenalan pola agar dapat mengetahui tekstur warna pada citra sehingga dapat melakukan identifikasi objek. Citra digital di implementasikan pada matriks dengan koordinat  $f(x,y)$  untuk menunjukkan tingkat kecerahan atau abu-abu gambar. Piksel atau bagian terkecil dari gambar adalah pembagian terhadap kolom dan baris. Representasi gambar digital dengan menggunakan persamaan sebagai berikut (1) [7]:

$$f(x,y) = \begin{pmatrix} f(0,0) & f(0,1) & \dots & f(0,N-1) \\ f(1,0) & f(1,1) & \dots & f(1,N-1) \\ \vdots & \vdots & \ddots & \vdots \\ (M-1,0) & f(M-1,1) & \dots & f(M-1,N-1) \end{pmatrix} \quad (1)$$

$f(x,y)$  merupakan fungsi dua variabel dengan matriks berukuran  $M \times N$ .  $M$  menyatakan jumlah baris dan  $N$  menyatakan jumlah kolom. Kemudian  $(x,y)$  adalah koordinat bidang.

A. Compressive Sensing

Compressive Sensing (CS) mengurangi atau kompresi sinyal agar dapat mengubah ukuran kapasitas pada sebuah gambar yang awalnya nilai ukurannya besar menjadi ukuran yang lebih kecil dari gambar aslinya. CS meningkatkan tingkat efisiensi rekonstruksi sinyal dengan menggunakan teori *Nyquist* kemudian dikembalikan ke sinyal asli dengan menggunakan proyeksi linear non-adaptif [2]. Laju data ditentukan dalam teori *Nyquist* dimana, frekuensi yang digunakan untuk melakukan pengambilan sampel harus memiliki nilai dua kali lipat dari frekuensi maksimum sinyal pesan. CS efektif saat keadaan *Sparse-Signal* atau sinyal jarang jika terdapat sinyal *non-Sparse* dapat dilakukan proses transformasi. Pemrosesan pada CS ini dilakukan dengan perkalian matrix menggunakan persamaan (2) dan (3) :

$$y = A \times x \quad (2)$$

$$\text{Rasio Kompresi} = \frac{L}{B^2} \times 100\% \quad (3)$$

Ukuran matriks  $A$  terdiri dari  $L \times B^2$  dan ukuran matriks  $x$  adalah  $B^2 \times 1$ . Sehingga ukuran matriks  $y$  adalah  $L \times 1$ . Setelah itu CS akan menghasilkan rasio kompresi untuk dapat mengetahui hasil terbaik sistem. Dengan  $L$  adalah Baris kompresi dan  $B$  adalah *Block*.

B. Discrete Cosine Transform (DCT)

Discrete Cosine Transform (DCT) merupakan transformasi bersifat *lossy compression* dengan mengubah sinyal dari keadaan tidak *sparse* ke bentuk *sparse*. DCT melakukan transformasi dari wilayah (domain) waktu ke

wilayah (domain) frekuensi kemudian merubah sinyal wilayah (domain) frekuensi menjadi sinyal *sparse*. DCT melakukan proses pada suatu citra dengan penjumlahan sinusoida dengan magnitudo dan frekuensi yang berbeda-beda dan sebaliknya dengan *Inverse Discrete Cosine Transform* (IDCT). DCT menggambarkan citra dengan menambahkan gelombang sinus dan frekuensi yang berubah-ubah. Transformasi dilakukan dengan menggunakan persamaan (4) dan (5) sebagai berikut [9][10].

$$x(k) = e(k) \sum_{n=0}^{N-1} x(n) \cos \left[ \frac{(2n+1)\pi k}{2N} \right], \text{ dengan nilai } k \text{ adalah } 0, 1, \dots, N-1 \quad (4)$$


$$1. \quad x(n) = \frac{2}{N} \sum_{k=0}^{N-1} e(k) x(k) \cos \left[ \frac{(2n+1)\pi k}{2N} \right], \text{ dengan nilai } n \text{ adalah } 0, 1, \dots, N-1 \quad (5)$$

$$e(k) = \begin{cases} \frac{1}{\sqrt{2}}, & \text{Jika nilai } k = 0 \\ 1, & \text{Jika nilai } k \text{ lebih dari } 0 \end{cases}$$

Dengan  $N$  adalah ukuran matriks,  $x(n)$  adalah nilai ke- $n$ ,  $\pi$  adalah jari-jari,  $e(k)$  bernilai 1 jika nilai  $k$  lebih dari 0, dan  $e(k)$  bernilai  $\frac{1}{\sqrt{2}}$  jika  $k$  bernilai 0.

C. Gray Level Co-Occurrence Matrix (GLCM)

Gray Level Co-Occurrence Matrix (GLCM) adalah salah satu teknik menentukan hubungan tekstur antara piksel secara statistik dengan melakukan perhitungan pada jarak dan sudut yang telah ditetapkan. Probabilitas statis pada metode GLCM sesuai dengan nilai abu-abu dari baris dan kolom. Jika nilai intensitasnya lebar dan ukuran matriksnya besar maka akan membutuhkan waktu proses yang lama [11]. Karakteristik statis didapatkan dengan menghitung *Co-Occurrence* yang digunakan untuk menghitung jarak dan sudut sehingga menghasilkan sebuah matriks dengan nilai pada baris dan kolom yang sama [5].  $P$  merupakan probabilitas statis orde dua dengan  $i$  dan  $j$  skala abu-abu, jarak perpindahan ( $d$ ), dan sudut tertentu ( $\theta$ ). Nilai 1 merupakan nilai untuk menentukan jarak perpindahan dan menggunakan sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$  (lihat Gambar 1)[12].



Gambar. 1 Arah GLCM.

1) *Quantization*: Proses *Quantization* bertujuan untuk mengurangi rentang sinyal dengan melakukan konversi nilai 0-255 nilai keabuan atau grayscale ke dalam nilai tertentu [13].

2) *Co-Occurrence*: Ko-okurensi atau kejadian bersama bertujuan untuk menentukan jarak dan sudut. Untuk orientasi sudut dibuat terhadap empat arah yaitu sudut 0 , 45 , 90 , dan 135 . Kemudian nilai 1 merupakan nilai untuk menentukan jarak perpindahan.

3) *Symmetric*: Proses pada simetris atau mirroring yaitu dengan menjumlahkan nilai matriks dengan nilai transposenya. Kemudian akan menghasilkan matriks yang simetris. Proses simetris dilakukan dengan menggunakan persamaan (6) sebagai berikut [14]:

$$\Sigma_I \text{simetris} = I + I^T \tag{6}$$

Dengan I adalah hasil matriks kookurensi dan  $I^T$  adalah hasil matriks kookurensi yang telah di transpose.

4) *Normalisasi*: Proses pembatasan nilai matriks sehingga hasilnya menjadi 0 sampai 1. okurensi yang telah di transpose. Proses normalisasi dilakukan dengan menggunakan persamaan (7) sebagai berikut [14]:

$$P_{i,j} = \frac{V(i,j)}{\sum_{i,j=0}^{N-1} V(i,j)} \tag{7}$$

Dengan,  $i$  adalah nilai pada baris,  $j$  adalah nilai pada kolom,  $V$  adalah nilai dalam matriks  $i,j$ ,  $P_{i,j}$  adalah probabilitas pada matriks  $i,j$ , dan  $N$  adalah jumlah baris atau kolom. Hasil yang didapatkan dengan menggunakan GLCM adalah melakukan perhitungan ciri tekstur dengan *Contrast*, *Correlation*, *Energy*, dan *Homogeneity* [8].

a) *Contrast*

*Contrast* merupakan pengukuran intensitas derajat keabuan antara piksel dengan piksel tetangganya. Perhitungan *Contrast* dengan menggunakan persamaan (8) [13]:

$$\sum_{i,j} (i-j)^2 \times x_{(i,j)} \tag{8}$$

Dengan  $i,j$  merupakan bilangan baris dan kolom lalu  $x_{(i,j)}$  merupakan probabilitas atau banyaknya nilai yang terdapat pada baris dan kolom.

b) *Correlation*

*Correlation* berfungsi sebagai perhitungan Kawasan linier dari derajat keabuan dalam matriks kookurensi. Korelasi menunjukkan piksel yang menjadi referensi kemudian dihubungkan dengan tetangganya. *Correlation* bernilai antara -1 hingga 1. Perhitungan *Correlation* dengan menggunakan persamaan (9) [12].

$$\sum_{i,j} \left[ \frac{(i-\mu_i)(j-\mu_j)x(i,j)}{\sigma_i \sigma_j} \right] \tag{9}$$

Dengan  $\mu_i = \sum_{i,j} ix(i,j)$  adalah rata-rata indeks kolom,  $\mu_j = \sum_{i,j} jx(i,j)$  adalah rata-rata indeks baris,  $\sigma_i = \sqrt{\sum_{i,j} (i-\mu_i)^2 x(i,j)}$  adalah jumlah indeks kolom,  $\sigma_j = \sqrt{\sum_{i,j} (j-\mu_j)^2 x(i,j)}$  adalah indeks baris, dan  $x(i,j)$  adalah probabilitas atau banyaknya nilai pada baris dan kolom.

c) *Energy*

*Angular Second Moment* (ASM) atau *Energy* merupakan nilai tingkat keabuan citra yang memiliki bentuk yang sangat mirip dengan piksel citra. Semakin tinggi kemiripan citra maka makin besar *energy*. Perhitungan *Energy* dilakukan dengan menggunakan persamaan (10) [12].

$$\sum_{i,j} [x_{(i,j)}]^2 \tag{10}$$

Dengan  $[x_{(i,j)}]^2$  merupakan probabilitas atau kemunculan yang terjadi di baris dan kolom yang dikuadratkan kemudian seluruh nilai dijumlahkan.

d) *Homogeneity*

*Homogeneity* mempunyai fungsi menghitung homogenitas lokal pada citra digital. Nilai *homogeneity* akan menjadi maksimum Ketika semua elemen pada citra sama. Perhitungan *Homogeneity* dengan menggunakan persamaan (11) [13].

$$\sum_{i,j} \frac{x(i,j)}{1+|i-j|} \tag{11}$$

Dengan  $x_{(i,j)}$  adalah nilai probabilitas atau kemunculan di baris dan kolom,  $|i-j|$  merupakan selisih absolut dari baris dan kolom.

D. *K-Nearest Neighbour* (K-NN)

*K- Nearest Neighbour* teknik yang digunakan sebagai proses klasifikasi pada suatu objek sesuai dengan ciri-ciri pada data latih yang mendekati objek. Klasifikasinya dengan menggunakan fungsi jarak antara ciri latih dan ciri uji [4]. Persamaan (12) merupakan persamaan yang digunakan untuk pengukuran perhitungan jarak dengan *Euclidean Distance* [5][15]:

$$D(v_1, v_2) = \sqrt{\sum_{k=1}^N (v_1(k) - v_2(k))^2} \tag{12}$$


Dengan  $D$  merupakan jarak dari gambar uji terhadap gambar latih,  $v_{1(k)}$  adalah data hasil ekstraksi fitur uji, dan  $v_{2(k)}$  adalah data hasil ekstraksi fitur latih.

III. METODE PENELITIAN

Penelitian mengenai pengaruh CS dalam klasifikasi jenis daun terdiri dari beberapa tahapan. Berikut adalah tahapan penelitian yang dilakukan.

A. Preprocessing

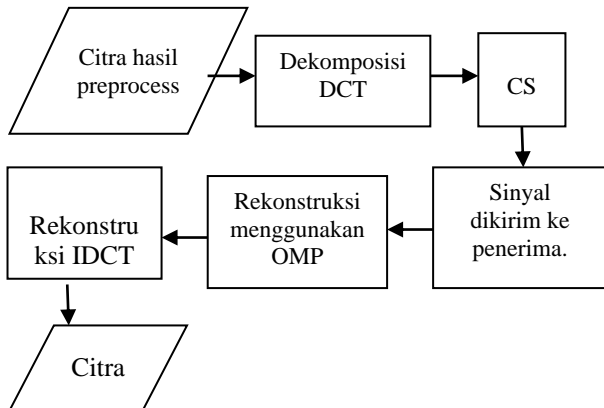
Preprocessing terhadap data asli dilakukan setelah memperoleh citra daun. Pada penelitian ini, dilakukan dua tahap *pre-processing* diantaranya *resizing citra daun dan konversi RGB ke citra grayscale*. Tujuan dari proses *resizing* adalah untuk menyeragamkan ukuran citra. Sementara itu, konversi citra dari citra RGB ke citra *grayscale* dilakukan dengan tujuan mengurangi kompleksitas komputasi. Tahap *pre-processing* yang dilakukan dapat dilihat pada Gambar 2.



Gambar. 2 Blok diagram Pre-processing.

B. Compressive Sensing

Setelah mendapatkan data dari proses *Preprocessing* kemudian tahapan selanjutnya melakukan proses kompresi dengan metode *Compressive Sensing (CS)*. Tahapan CS yang dilakukan ditunjukkan pada Gambar 3.



Gambar. 3 Blok diagram Compressive Sensing

Citra keluaran *pre-processing* selanjutnya masuk ke dalam tahap CS. *Compressive Sensing* dapat mengubah ukuran kapasitas pada sebuah gambar yang awalnya nilai ukurannya besar menjadi ukuran yang lebih kecil dari gambar aslinya serta meningkatkan tingkat efisiensi rekonstruksi sinyal dengan menggunakan teori *Nyquist* kemudian dikembalikan ke sinyal asli dengan menggunakan proyeksi linear non-adaptif.

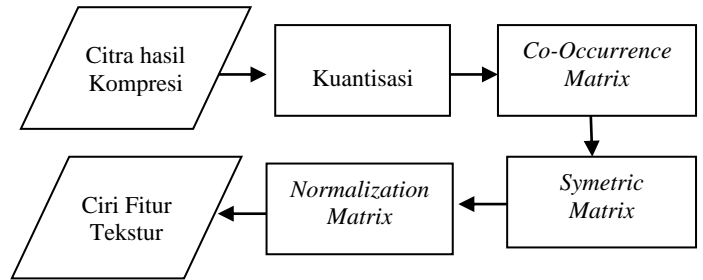
Tahap CS dimulai dengan mendekomposisikan citra dengan metode Discrete Cosine Transform (DCT). DCT melakukan transformasi dari wilayah (domain) waktu ke wilayah (domain) frekuensi kemudian mengubah sinyal wilayah (domain) frekuensi menjadi sinyal *sparse*.

Selanjutnya dilakukan CS dengan berbagai rasio kompresi. Citra hasil CS dikirim ke penerima untuk selanjutnya dilakukan rekonstruksi menggunakan metode

Orthogonal Matching Pursuit (OMP). Hasil rekonstruksi dengan OMP selanjutnya dilakukan proses *Inverse DCT*.

C. Gray Level Co-occurrence Matrix (GLCM)

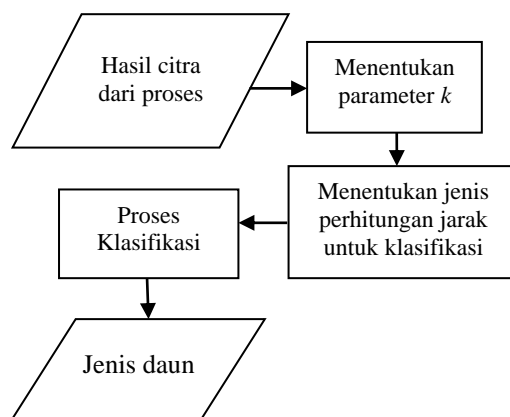
Proses ekstraksi fitur dilakukan dengan tujuan untuk memperoleh ciri pada sampel daun. Ciri yang sudah didapatkan akan digunakan sebagai pembeda jenis dari setiap sampel daun. Gambar 4 menunjukkan proses ekstraksi ciri menggunakan metode GLCM.



Gambar. 4 Blok diagram Ekstraksi Ciri dengan GLCM

Proses ekstraksi fitur diawali dengan melakukan proses Kuantisasi terhadap citra *grayscale* keluaran proses CS. Selanjutnya dilakukan tahap ko-okurensi. Ko-okurensi atau kejadian bersama bertujuan untuk menentukan jarak dan sudut. Untuk orientasi sudut dibuat terhadap empat arah yaitu sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$ . Kemudian nilai 1 merupakan nilai untuk menentukan jarak perpindahan. Tahap ketiga adalah proses simetris. Proses pada simetris atau mirroring yaitu dengan menjumlahkan nilai matriks dengan nilai transposnya. Kemudian akan menghasilkan matriks yang simetris.

D. K-Nearest Neighbor (K-NN)



Gambar. 5 Blok diagram Klasifikasi dengan K-NN

Proses klasifikasi K- NN dilakukan menggunakan data keluaran ekstraksi ciri berupa ciri statistik orde dua yang telah dihitung sebelumnya, yang terdiri dari nilai *contrast*, *correlation*, *energy* dan *homogeneity*. Klasifikasi dilakukan dengan membandingkan nilai ciri yang ada pada database ciri latih, untuk kemudian dibandingkan dengan ciri uji yang diperoleh. Tahapan dari proses klasifikasi ditunjukkan pada Gambar 5.

Proses klasifikasi dimulai dengan menentukan parameter  $k$ , kemudian menentukan jenis perhitungan jarak. Klasifikasi dilakukan dengan menghitung jarak antara ciri uji dengan ciri latih untuk kemudian diketahui jenis daunnya.

IV. HASIL DAN PEMBAHASAN

Pengujian sistem dilakukan dengan menguji beberapa parameter seperti rasio jumlah data uji dan data latih,, nilai *Block*, nilai baris kompresi, *Resize*, *Compressive Sensing*, dan tanpa *Compressive Sensing*. Jumlah data latih dan data uji sebanyak 32 citra dan 16 citra dengan perbandingan data latih dan data uji yaitu 20:4, 32:4, 20:8, 32:8, 20:12, 32:12, 20:16, dan 32:16. Nilai *resize* yang digunakan yaitu  $128 \times 128$ ,  $256 \times 256$ , dan  $512 \times 512$  piksel. Nilai tersebut diubah-ubah sehingga hasil yang didapatkan mempengaruhi nilai pada rasio kompresi, PSNR, akurasi saat melakukan pengujian. Daun yang digunakan dalam penelitian ini yaitu daun mangga, daun jambu, daun jeruk, dan daun siri. Gambar 6 menunjukkan sampel dari citra daun yang digunakan pada proses klasifikasi.



Gambar. 6 Sampel Citra Daun.

A. Hasil Pengujian Klasifikasi Jenis Daun Tanpa Menggunakan *Compressive Sensing*

Pengujian pada skenario pertama dilakukan tahapan klasifikasi jenis daun tanpa dilakukan penerapan metode CS terlebih dahulu pada citra sebelum di klasifikasikan.

TABEL I  
HASIL EKSTRAKSI FITUR TANPA CS

No.	Data Latih	Data Uji	Resize	Akurasi
1	20	16	128	100 %
2	20	16	256	100 %
3	20	16	512	100 %
4	20	16	128	100 %
5	20	16	256	100 %
6	20	16	512	100 %
Rata- Rata Nilai				100%

Dari Tabel 1 terlihat bahwa nilai rata-rata akurasi yang didapatkan tanpa menggunakan CS yaitu bernilai 100%. Artinya semua jenis daun terklasifikasi dengan baik di penerima. Namun demikian, ukuran file citra daun yang dikirimkan masih cukup besar karena tidak dilakukan kompresi terlebih dahulu terhadap citra daun yang dikirimkan.

B. Hasil Pengujian Klasifikasi Jenis Daun dengan *Compressive Sensing*

Pengujian pada skenario kedua dilakukan tahapan klasifikasi jenis daun dengan penerapan metode CS terlebih dahulu pada citra sebelum di klasifikasikan.

TABEL II  
HASIL EKSTRAKSI FITUR DENGAN CS

No.	L	Resize	Hasil Analisis		
			Rasio Kompresi (%)	PSNR (dB)	Akurasi (%)
1.	4	128	0,3	16	75
2.	4	256	0,3	14,5	100
3.	4	512	0,3	19,8	100
4.	8	128	0,7	15,1	75
5.	8	256	0,7	17,5	75
6.	8	512	0,7	18,5	75
7.	16	128	1,5	15,1	75
8.	16	256	1,5	17,2	75
9.	16	512	1,5	20,4	100
10.	32	128	3,1	16,9	75
11.	32	256	3,1	19,6	75
12.	32	512	3,1	22,1	100

Tabel 2 menunjukkan hasil pengujian siste klasifikasi jenis daun dengan menggunakan *Compressive Sensing*. Dengan menggunakan data latih bernilai 20, data uji bernilai 4, *block* yang digunakan bernilai 32, L (Baris Kompresi) yang digunakan bernilai 32, dan *resize* bernilai  $512 \times 512$ . Dapat disimpulkan bahwa dengan hasil paling optimum yaitu rasio kompresi bernilai 3,1%, PSNR bernilai 22,1 dB, dan nilai Akurasi adalah 100%.

C. Pengaruh Nilai *Block* dan Baris kompresi

Pengujian *Block based* dengan melakukan proses pada setiap blok-bloknya dengan cara melakukan *looping* kearah kanan dan ke bawah atau baris dan kolom. Didalam proses *looping* dilakukan proses 1 blok. Sehingga rumus untuk *Block* ( $B$ ) adalah  $B^2$ . Baris kompresi merupakan nilai 0,5 dari nilai *Block* ( $B$ ).

TABEL III  
HASIL EKSTRAKSI FITUR DAUN YANG DIPENGARUHI OLEH NILAI BLOCK DAN BARIS KOMPRESI

No.	Block	L	Hasil	
			PSNR (dB)	Akurasi (%)
1.	32	32	16,5	50
2.	32	32	18,3	41,6
3.	32	32	22,3	58,3
4.	32	32	16,5	50
5.	32	32	19,5	41,6
6.	32	32	22,1	58,3
7.	32	32	16,1	56,2
8.	32	32	17,6	62,5
9.	32	32	19,4	56,2
10.	32	32	17,1	50
11.	32	32	19,4	62,5
12.	32	32	21,4	75
13.	32	32	17,2	100
14.	32	32	19,6	75

No.	Block	L	Hasil	
			PSNR (dB)	Akurasi (%)
15.	32	32	22,8	75
16.	32	32	16,9	75
17.	32	32	19,6	75
18.	32	32	22,1	100
19.	32	32	16,3	56,2
20.	32	32	19,1	62,5
21.	32	32	22,6	68,7
22.	32	32	16,3	50
23.	32	32	19,1	62,5
24.	32	32	21,4	50
Rata-Rata			19,1 dB	63,30%

Tabel 3 menunjukkan bahwa dengan menggunakan ukuran blok 32 dan baris kompresi 32 didapatkan hasil rata-rata PSNR 19,1 dB dan akurasi 63,3% dari 24 citra daun yang diuji.

**D. Pengaruh Resize dan Baris kompresi**

Resize pada citra adalah proses pengubahan ukuran atau resolusi secara horizontal dan vertikal. Ukuran citra yang diujikan yaitu 128 × 128, 256 × 256, 512 × 512. Kemudian dilakukan pengujian sistem sesuai dengan parameter yang digunakan.

TABEL IV  
HASIL EKSTRAKSI FITUR DAUN DENGAN UKURAN CITRA 128 x 128

No	Block	Baris Kompresi	Hasil PSNR	Akurasi	Data Latih : Data Uji
1.	32	4	0,6	91,6	20:12
2.	32	8	8,2	75	
3.	32	16	15,4	50	
4.	32	32	16,5	58,3	
5.	32	4	5,7	91,6	32:12
6.	32	8	13,3	58,3	
7.	32	16	15	41,6	
8.	32	32	16,5	50	
9.	32	4	0,9	75	32:16
10.	32	8	14,1	81,2	
11.	32	16	15,2	37,5	
12.	32	32	16,1	56,2	
13.	32	4	10,5	75	32:8
14.	32	8	12,8	62,5	
15.	32	16	15,2	50	
16.	32	32	17,1	50	
17.	32	4	10,6	50	32:4
18.	32	8	14,6	75	
19.	32	16	14,9	75	
20.	32	32	17,2	100	
21.	32	4	16	75	20:4
22.	32	8	15,1	75	
23.	32	16	15,1	75	
24.	32	32	16,9	75	
25.	32	4	9,9	93,7	20:16
26.	32	8	9,8	56,2	
27.	32	16	14,5	81,2	
28.	32	32	16,3	56,2	

No	Block	Baris Kompresi	Hasil PSNR	Akurasi	Data Latih : Data Uji
29.	32	4	15,6	50	20:8
30.	32	8	15	87,5	
31.	32	16	14,9	50	
32.	32	32	16,3	50	
Rata-Rata			13,3 dB	66,5%	

TABEL V  
HASIL EKSTRAKSI FITUR DAUN DENGAN UKURAN CITRA 256 x 256

No	Block	Baris Kompresi	Hasil PSNR	Akurasi	Data Latih : Data Uji
1.	32	4	8,3	91,6	20:12
2.	32	8	16,8	58,3	
3.	32	16	16	50	
4.	32	32	18,3	41,6	
5.	32	4	16,2	83,3	32:12
6.	32	8	9,8	66,6	
7.	32	16	19,5	50	
8.	32	32	19,5	41,6	
9.	32	4	0,8	87,5	32:16
10.	32	8	16,7	50	
11.	32	16	16,7	50	
12.	32	32	17,6	62,5	
13.	32	4	16,1	62,5	32:8
14.	32	8	17,1	62,5	
15.	32	16	17	50	
16.	32	32	19,4	62,5	
17.	32	4	5,2	75	32:4
18.	32	8	16,1	50	
19.	32	16	17,9	50	
20.	32	32	19,6	75	
21.	32	4	14,5	100	20:4
22.	32	8	17,5	75	
23.	32	16	17,2	75	
24.	32	32	19,6	75	
25.	32	4	11,2	56,2	20:16
26.	32	8	17,5	68,7	
27.	32	16	17,9	62,5	
28.	32	32	19,1	62,5	
29.	32	4	18,3	87,5	20:8
30.	32	8	17,4	62,5	
31.	32	16	16,7	62,5	
32.	32	32	19,1	62,5	
Rata-Rata			15,9 dB	64,7%	

Tabel 4, 5 dan 6 merupakan hasil pengukuran PSNR dan akurasi rata-rata dengan menggunakan berbagai ukuran citra. Dari ketiga tabel tersebut dapat disimpulkan bahwa hasil rata-rata nilai PSNR tertinggi diperoleh ketika digunakan citra dengan ukuran 512 × 512 yaitu bernilai 18,8 dB. Hal ini terjadi karena nilai PSNR menjadi perkiraan persepsi visual manusia terhadap citra hasil rekonstruksi sehingga nilai PSNR semakin baik ketika digunakan ukuran citra yang semakin besar.

Sementara itu untuk hasil Akurasi tertinggi diperoleh ketika digunakan citra dengan ukuran  $128 \times 128$  yaitu bernilai 66,5%. Hal ini terjadi karena ukuran citra yang kecil akan memberikan detail yang lebih baik, karena setiap piksel mewakili informasi dari citra tersebut.

TABEL V  
HASIL EKSTRAKSI FITUR DAUN DENGAN UKURAN CITRA 512 x 512

No	Block	Baris Kompresi	Hasil		Data Latih : Data Uji
			PSNR	Akurasi	
1.	32	4	0,8	75	20:12
2.	32	8	20	58,3	
3.	32	16	18,7	75	
4.	32	32	22,3	58,3	
5.	32	4	11,1	41,6	32:12
6.	32	8	20,2	41,6	
7.	32	16	19,9	50	
8.	32	32	22,1	58,3	
9.	32	4	18,7	75	32:16
10.	32	8	20	56,2	
11.	32	16	19,9	50	
12.	32	32	19,4	56,2	
13.	32	4	16,9	87,5	32:8
14.	32	8	15,6	75	
15.	32	16	20,1	75	
16.	32	32	21,4	75	
17.	32	4	11,1	50	32:4
18.	32	8	19,9	25	
19.	32	16	21,3	75	
20.	32	32	22,8	75	
21.	32	4	19,8	100	20:4
22.	32	8	18,5	75	
23.	32	16	20,4	100	
24.	32	32	22,1	100	
25.	32	4	15,2	75	20:16
26.	32	8	18,7	68,7	
27.	32	16	21	62,5	
28.	32	32	22,6	68,7	
29.	32	4	21,1	62,5	20:8
30.	32	8	20,2	62,5	
31.	32	16	18,5	50	
32.	32	32	21,4	50	
Rata-Rata			18,8 dB	65,8%	

V. KESIMPULAN

Penelitian ini melakukan pengujian terhadap klasifikasi jenis daun menggunakan metode *Gray Level Co-Occurance Matrix* (GLCM) dan metode klasifikasi *k-Nearest Neighbor* (k-NN). Namun sebelum dilakukan klasifikasi di penerima, terlebih dahulu dilakukan kompresi terhadap citra daun yang akan dikirimkan menggunakan *Compressive Sensing*. Pengujian terhadap sistem ini dilakukan ketika dilakukan kompresi dan ketika tidak dilakukan kompresi. Kedua skenario ini digunakan untuk mengetahui nilai rasio kompresi, nilai PSNR, dan nilai Akurasi paling optimal. Akurasi terbaik ketika tidak dilakukan kompresi menggunakan CS adalah 100%.

Sementara itu, ketika dilakukan kompresi menggunakan CS, hasil terbaik yang diperoleh diantaranya adalah rasio kompresi 3,1%, PSNR 22,1 dB dan akurasi terbaik 100%.

REFERENSI

- [1] M. Rojanamontien, P. Sihanatkathakul, N. Piemkaroonwong, and S. Kamales, "Leaf Identification Using Apical and Basal Features," *2016 8th Int. Conf. Knowl. Smart Technol. IEEE*, pp. 234–238, 2016, doi: 10.1109/KST.2016.7440521.
- [2] Emmanuel J. Candès and Michael B. Wakin, *An Introduction To Compressive Sampling*, vol. 25, no. 2. 2008.
- [3] L. Yan, J. S. Pan, and X. Zhu, "Feature extraction based on nearest feature line and compressive sensing," *2013 Ninth Int. Conf. Intell. Inf. Hiding Multimed. Signal Process. IEEE*, pp. 354–357, 2013, doi: 10.1109/IH-MSP.2013.95.
- [4] O. R. Indriani, E. J. Kusuma, C. A. Sari, E. H. Rachmawanto, and D. R. I. M. Setiadi, "Tomatoes classification using K-NN based on GLCM and HSV color space," *Proc. - 2017 Int. Conf. Innov. Creat. Inf. Technol. Comput. Intell. IoT, ICITech IEEE*, pp. 1–6, 2018, doi: 10.1109/INNOCIT.2017.8319133.
- [5] G. M. A. K. Usman, dan R. Y. Nur'fuadah, "Classification of Tea Leaves Using Method Gray Level Co- Occurance Matrix (GLCM) and K-Nearest Neighbor (K-NN)," *Univ. Telkom, SI Tek. Telekomun.*, p. 5, 2019, [Online].
- [6] L. Safira, B. Irawan, and C. Setianingsih, "K-nearest neighbour classification and feature extraction GLCM for identification of terry's nail," *2019 IEEE Int. Conf. Ind. 4.0, Artif. Intell. Commun. Technol. K-Nearest*, pp. 98–104, 2019, doi: 10.1109/ICIAICT.2019.8784856.
- [7] S. R. Regina, K. Usman, N. Kumalasari, dan C. Pratiwi, "Identifikasi Jenis Bawang Merah Berdasarkan Tekstur dan Warna Dengan Ekstraksi Ciri GLCM dan Klasifikasi K-NN," pp. 1–7, 2019.
- [8] I. G. R. A. Sugiarta, M. Sudarma, dan I. M. O. Widyantara, "Ekstraksi Fitur Warna, Tekstur dan Bentuk untuk Clustered-Based Retrieval of Images (CLUE)," *Maj. Ilm. Teknol. Elektro*, vol. 16, no. 1, p. 86, 2016, doi: 10.24843/mite.1601.12.
- [9] R. PURNAMASARI dan A. B. SUKSMONO, "Compressive Sampling untuk Sinyal Beat Radar Cuaca via Discrete Cosine Transform (DCT)," *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, vol. 7, no. 2, p. 238, 2019, doi: 10.26760/elkomika.v7i2.238.
- [10] I. Naomi, C. Sinaga, I. I. T. S. T. N. Caecar, dan S. T. Kumalasari, "Klasifikasi Tingkat Kematangan Buah Kakao Menggunakan Metode Discrete Cosine Transform Dan K-Nearest Neighbor Classification of Cacao Pods Ripeness Level Using Discrete Cosine Transform and K-Nearest Neighbor," vol. 7, no. 1, pp. 776–783, 2020.
- [11] Ş. Öztürk and B. Akdemir, "Application of Feature Extraction and Classification Methods for Histopathological Image using GLCM, LBP, LBGLCM, GLRLM and SFTA," *Procedia Comput. Sci.*, vol. 132, no. Iccids, p. 42, 2018, doi: 10.1016/j.procs.2018.05.057.
- [12] P. Mohanaiah, P. Sathyanarayana, and L. Gurukumar, "Image Texture Feature Extraction Using GLCM Approach," *Int. J. Sci. Res. Publ.*, vol. 3, no. 5, p. 1, 2013.
- [13] Y. Rullist, B. Irawan, dan A. B. Osmond, "Batik'S Pattern Identification Through Feature Extraction Method, Gray Level Co - Occurrence Matrix (GlcM), Based on Android," *e-Proceeding Eng.*, vol. 2, no. 2, pp. 3684–3692, 2015.
- [14] P. D. Mryka Hall-Beyer, *GLCM TEXTURE: A TUTORIAL*, vol. 2, no. March. 2017.
- [15] Saidah, S., Adinegara, M. B., Magdalena, R., Kumalasari, N., Pratiwi, C., & Elektro, F. T. (2019). Identifikasi Kualitas Beras Menggunakan Metode k-Nearest Neighbor dan Support Vector Machine Rice Quality Identification using k-Nearest Neighbor and Support Vector Machine Method. *Telka*, 5(2), 114–121..