

Implementasi Metode *K-Means* untuk *Clustering* Citra Tanaman Obat

Rizky Prabowo¹, Vira Verina², Ridho Sholehurrohman³, Rico Andrian⁴

^{1,2,3,4}Jurusan Ilmu Komputer, FMIPA, Universitas Lampung
Jl. Prof. Dr. Ir. Sumantri Brojonegoro No.1, Gedong Meneng, Kec. Rajabasa, Kota
Bandar Lampung, Lampung 35141 (0721) 701609
e-mail: 1rizky.prabowo@fmipa.unila.ac.id, 2viravrna@gmail.com,
3ridho.sholehurrohman@fmipa.unila.ac.id, 4rico.andrian@fmipa.unila.ac.id

Abstract

Medicinal plants have significant benefits in treating various diseases. Many communities utilize medicinal plants as a source of family herbal medicine (TOGA). The part of the plant that is often used for medicinal purposes is the leaves. Identifying leaves can be challenging as many of them have similar shapes and colors. Therefore, image processing with K-Means Clustering is applied to aid in the identification of medicinal plant leaves. The leaf images are scaled to 600 x 800 pixels. The texture features of the images are computed using the Gray Level Co-occurrence Matrix (GLCM) method. GLCM generates numerical values that are later used in the K-Means Clustering process. K-Means Clustering method groups the images based on the similarity of their feature values and their closest centroids. The optimal number of clusters is determined to be $k=3$ based on the calculation of the Sum of Squared Errors (SSE). The results show that out of 900 leaf image datasets, the K-Means Clustering divides them into 3 clusters, with the highest accuracy of 51.54% achieved in cluster 2, which predicts the binahong leaves. K-Means Clustering process is less effective due to the influence of centroid initialization on the clustering results. K-Means Clustering is implemented into a web-based system using Flask.

Keywords: *K-Means Clustering, Gray Level Co-occurrence Matrix (GLCM), Medicinal Plant, Flask*

Abstrak

Tanaman obat memiliki manfaat besar dalam menyembuhkan berbagai penyakit. Banyak masyarakat yang menggunakan tanaman obat sebagai sumber tanaman obat keluarga (TOGA). Bagian tanaman yang dapat dimanfaatkan sebagai obat adalah daun. Daun sulit diidentifikasi karena banyak daun yang memiliki bentuk dan warna yang mirip. Oleh karena itu, pengolahan citra dengan K-Means Clustering diterapkan untuk membantu mengidentifikasi daun tanaman obat. Citra akan discaling menjadi 600 x 800 piksel. Ciri tekstur pada citra akan dihitung menggunakan Gray Level Co-occurrence Matrix (GLCM). GLCM menghasilkan nilai numerik yang kemudian digunakan untuk proses K-Means Clustering. K-Means Clustering akan mengelompokkan citra berdasarkan kesamaan nilai fitur dan centroid terdekatnya. Jumlah cluster optimal yaitu $k=3$ berdasarkan perhitungan nilai SSE. Hasil penelitian 900 dataset citra daun terbagi menjadi 3 cluster dengan

akurasi tertinggi 51,54% pada cluster 2 yang memprediksi daun binahong. Proses K-Means Clustering kurang baik dikarenakan penentuan nilai centroid berpengaruh terhadap hasil cluster. K-Means Clustering diimplementasikan ke dalam sistem web menggunakan flask.

Kata kunci—K-Means Clustering, Gray Level Co-occurrence Matrix (GLCM), Tanaman Obat, Flask

1. PENDAHULUAN

Tanaman obat merupakan tumbuhan yang memiliki manfaat untuk menyembuhkan berbagai penyakit. Tanaman obat pada umumnya dimanfaatkan sebagai obat tradisional atau sebagai bahan baku obat kimiawi[1]. Daun merupakan bagian tanaman yang dapat digunakan sebagai obat. Daun pada umumnya berwarna hijau dan memiliki bentuk yang mirip, sehingga jika dilihat sekilas oleh manusia sulit untuk dibedakan.

Pengolahan citra dapat membantu manusia untuk mengidentifikasi daun tanaman obat. Pengolahan citra adalah proses mengolah citra menggunakan komputer. Tahap awal pengolahan citra adalah *preprocessing*, citra disiapkan dan disesuaikan, seperti menyamakan ukuran citra dan mengubah warna citra. Selanjutnya, melakukan ekstraksi fitur untuk mengambil ciri dari citra agar citra dapat diidentifikasi. Salah satu metode ekstraksi fitur adalah *Gray Level Co-occurrence Matrix* (GLCM), yang digunakan untuk menganalisis tekstur citra dengan memperhatikan hubungan spasial piksel yang memiliki intensitas warna keabuan[2].

Hasil pengolahan citra akan dikelompokkan berdasarkan kesamaan karakteristik citra. Kelompok-kelompok ini disebut *cluster*, di mana setiap *cluster* berisi citra yang serupa dalam satu *cluster* tetapi berbeda dari *cluster* lainnya. *Clustering* merupakan proses membagi data menjadi beberapa *cluster*. *Clustering* termasuk salah satu metode *unsupervised learning*. Metode *clustering* yang digunakan yaitu *K-Means*. *K-Means Clustering* melakukan pengelompokkan data berdasarkan jarak terpendek ke *centroid* dan dilakukan secara iteratif[3].

Peneliti S. Desmanto & R. Angreni (2014) menerapkan *K-Means Clustering* dalam pengelompokkan citra digital[4]. Penelitian ini menggunakan 50 citra digital, lalu mengelompokkan citra berdasarkan kemiripan warna yang menghasilkan akurasi sebesar 83%. Citra yang memiliki warna serupa akan dikelompokkan dalam satu *cluster*. Dalam pengujian 30 citra dengan *centroid* awal data citra 1, citra 2, dan citra 3,

diperoleh 3 *cluster*. *Cluster* 1 memiliki 5 citra, *cluster* 2 memiliki 15 citra, dan *cluster* 3 memiliki 10 citra. Sedangkan, pengujian 30 citra dengan *centroid* awal data citra 4, citra 5, dan citra 6 menghasilkan 3 *cluster* dengan jumlah citra pada *cluster* 1 sebanyak 13 citra, *cluster* 2 sebanyak 10 citra, dan *cluster* 3 sebanyak 7 citra. Berdasarkan hasil tersebut terbukti penentuan nilai *centroid* berpengaruh terhadap hasil *cluster*.

Penelitian yang dilakukan oleh Atina pada tahun 2017 mengenai segmentasi citra paru menggunakan metode *K-Means Clustering* menemukan hasil terbaik ketika jumlah cluster adalah 8[5]. Citra yang dihasilkan dengan $k = 8$ menghasilkan visualisasi pembentukan warna yang lebih nyata dan jelas. Menurutnya, citra ini dapat dijadikan data untuk *Computerized Aid Diagnose* (CAD) yang digunakan dalam mendeteksi jenis penyakit pada paru secara komputerisasi. Penelitian tersebut menunjukkan bahwa pengolahan citra memiliki potensi dalam mengidentifikasi citra dengan baik. Penulis membahas penelitian dengan judul "Implementasi Metode *K-Means* untuk *Clustering* Citra Tanaman Obat".

2. METODE PENELITIAN


2.1 Studi Literatur

2.1.1 Tanaman Obat

Tanaman obat adalah jenis tumbuhan yang memiliki kemampuan untuk mencegah dan menyembuhkan penyakit. Tanaman obat dapat diolah secara alami sebagai bahan dasar pembuatan obat tradisional dan juga bisa digunakan sebagai bahan baku dalam pembuatan obat kimiawi. Tanaman obat dapat digunakan dalam bentuk minuman, obat oles, atau dihirup[6]. Tanaman obat bisa tumbuh secara liar atau ditanam secara sengaja di pekarangan rumah. Masyarakat biasanya menanam tanaman obat di pekarangan rumah sebagai sumber tanaman obat keluarga (TOGA).

2.1.2 *K-Means Clustering*

K-Means Clustering merupakan metode untuk mengelompokkan data dengan membagi suatu *dataset* menjadi k *cluster*. Tujuannya untuk mengurangi kesamaan karakteristik data antar *cluster* dan meningkatkan kesamaan karakteristik data di dalam satu *cluster*[7]. Ilustrasi proses *K-Means Clustering* dapat dilihat pada Gambar 1.



Gambar 1. Ilustrasi Proses *K-Means Clustering*

Proses *K-Means Clustering* adalah sebagai berikut:

- Menentukan jumlah k cluster. Pilih k data secara acak sebagai *centroid* awal.
- Setelah *centroid* awal terbentuk, hitung jarak setiap data ke *centroid* terdekat menggunakan rumus *Euclidean Distance*:

$$d(x, y) = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad (1)$$

- Didapat anggota *cluster* berdasarkan jarak data ke *centroid* bernilai paling kecil (jarak terpendek).
- Hitung *centroid* baru menggunakan rumus mencari *centroid*:

$$centroid_i = \frac{\sum_{j=1}^n x_j}{n} \quad (2)$$

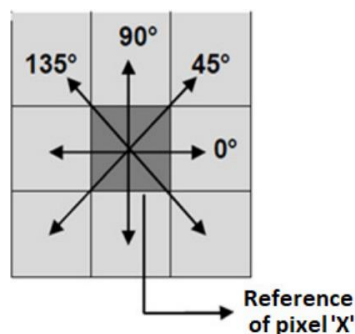
- Ulangi langkah 2 sampai 4 hingga tidak ada lagi data yang berpindah ke *cluster* lain.

2.1.3 Pengolahan Cira Digital

Pengolahan citra digital adalah pengolahan citra dua dimensi $f(x,y)$ menjadi bentuk citra lain menggunakan komputer. Beberapa teknik umum yang sering digunakan dalam pengolahan citra digital adalah citra *grayscale*, citra biner, dan citra warna (RGB) [8]. Citra yang digunakan dalam penelitian ini yaitu citra warna (RGB) dan citra *grayscale*. Citra RGB adalah citra yang memiliki 3 komponen warna yaitu merah (*Red*), hijau (*Green*), dan biru (*Blue*) pada setiap pikselnya. Citra *grayscale* adalah citra keabuan yang hanya memiliki satu nilai pada setiap pikselnya.

2.1.4 Gray Level Co-occurrence Matrix (GLCM)

Gray Level Co-occurrence Matrix (GLCM) adalah metode ekstraksi fitur yang digunakan untuk menganalisis tekstur citra. GLCM merepresentasikan hubungan ketetanggaan dua piksel yang memiliki intensitas warna keabuan dalam jarak dan sudut tertentu[9]. Orientasi sudut yang digunakan berdasarkan arah 0°, 45°, 90°, atau 135°. Tekstur merupakan karakteristik yang dimiliki suatu citra. Pada proses ini nilai citra akan dihitung berdasarkan fitur *contrast*, *homogeneity*, *energy*, dan *correlation*.



Gambar 2. Arah Sudut GLCM

2.1.5 Python

Python adalah bahasa pemrograman yang memiliki *syntax* sederhana dan sering digunakan di dunia pendidikan dan perusahaan besar, terutama oleh perusahaan yang bergerak dalam pembuatan dan pengembangan aplikasi[10]. *Python* juga banyak digunakan dalam bidang *data science* dan *machine learning*. *Library* yang digunakan yaitu *NumPy*, *Pandas*, *Matplotlib*, *Scikit Learn*, dan *OpenCV*. *Python* memiliki *web framework* yang digunakan untuk membuat sebuah *website* yaitu *flask*[11].

2.2 Pengembangan Sistem

2.2.1 Requirement

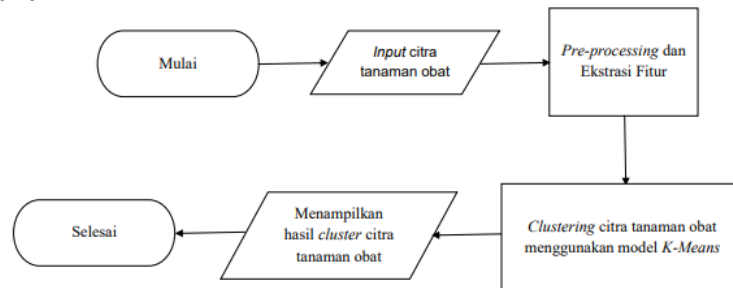
Requirement merupakan tahap menganalisis kebutuhan *fungsi*ional dan *non fungsi*ional untuk pengembangan sistem. Kebutuhan *fungsi*ional sistem yaitu pengguna dapat menginput citra tanaman obat. Sistem dapat menentukan *cluster* citra, lalu menampilkan hasil *clustering* citra. Kebutuhan *non fungsi*ional:

- Perangkat Keras: *Processor Intel(R) Core(TM) i5-8265U*, RAM 4GB, VGA NVIDIA GeForce MX230.
- Perangkat Lunak: *Windows 11*, *Python 3*, *Jupyter Notebook*, *VSCode*, *Flask*, *Library(Numpy, Pandas, Matplotlib, Scklearn, OpenCV)*.

2.2.2 Design

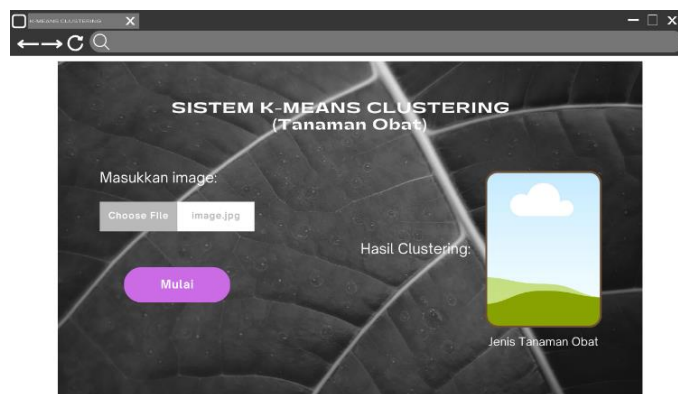
Design merupakan tahap perancangan sistem sesuai dengan *requirement*. Tahap dari *design* yaitu membuat *flowchart* dan *design interface*.

a. Flowchart



Gambar 3. Flowchart Sistem

b. Interface



Gambar 4. Design Interface

2.2.3 Implementation

Implementation merupakan tahap eksekusi *design* ke dalam bentuk kode program dan dikembangkan menggunakan *web framework flask*.

2.2.4 Verification

Verification merupakan tahap pemeriksaan fungsi-fungsi pada sistem sesuai dengan *requirement* yang telah ditentukan.

3. HASIL DAN PEMBAHASAN

3.1 Preprocessing Citra

Preprocessing yang digunakan yaitu *scaling* seluruh data citra daun menjadi ukuran 600 x 800 piksel. *Scaling* citra ini merubah ukuran piksel citra menjadi skala yang lebih kecil.

3.2 Ekstraksi Fitur GLCM

GLCM memperhitungkan nilai *correlation*, *homogeneity*, *contrast*, dan *energy* dengan arah sudut 0°, 45°, 90° atau 135°. Perhitungan GLCM menghasilkan nilai numerik, kemudian disimpan dalam bentuk *excel*. Hasil perhitungan GLCM untuk sampel citra daun binahong ditunjukkan pada Tabel 1.

Tabel 1. Hasil Perhitungan GLCM Daun Binahong

GLCM	0°	45°	90°	135°	Rata-rata
<i>Correlation</i>	0,991017	0,993621	0,991993	0,995595	0,993056
<i>Homogeneity</i>	0,450025	0,492515	0,458915	0,503794	0,476312
<i>Contrast</i>	75,69122	53,74952	67,46385	37,11829	58,50572
<i>Energy</i>	0,058162	0,062704	0,059962	0,064864	0,061423

Tabel 1 merupakan sampel citra daun binahong yang dihitung nilai fitur *correlation*, *homogeneity*, *contrast*, dan *energy* terhadap sudut 0°, 45°, 90° atau 135°. Rata-rata untuk masing-masing fitur akan digunakan untuk proses *K-Means Clustering*.

3.3 K-Means Clustering

Proses *K-Means Clustering* yaitu menentukan jarak setiap data ke *centroid* untuk membentuk sebuah *cluster*. Penelitian ini menggunakan nilai $k = 3$, dimana k merupakan jumlah *cluster* yang diinginkan. 10 sampel *dataset* citra daun diperoleh nilai rata-rata setiap fitur GLCM untuk melakukan proses *K-Means Clustering*.

Tabel 2. Rata-rata Nilai Fitur dari 10 Data

Data	R_corr	R_hom	R_cont	R_eng
1	0,993056	0,476312	58,50572	0,061423
2	0,995568	0,629386	52,28695	0,105851

3	0,99153	0,572671	100,8635	0,076212
4	0,994942	0,640498	42,27761	0,082310
5	0,995747	0,506265	28,23942	0,058442
6	0,991602	0,521792	87,2991	0,089216
7	0,996905	0,579667	21,69937	0,068690
8	0,993156	0,636986	29,53128	0,128024
9	0,988355	0,507189	106,2014	0,068514
10	0,993297	0,639449	49,98901	0,082648

Keterangan Tabel 2:

- R_corr = Rata-rata fitur correlation
- R_hom = Rata-rata fitur homogeneity
- R_cont = Rata-rata fitur contrast
- R_eng = Rata-rata fitur energy

Tabel 2 menunjukkan 10 sampel *dataset* citra daun memiliki nilai fitur yang berbeda. Perbedaan dari nilai fitur menggambarkan karakteristik tekstur citra yang berbeda. Berdasarkan Tabel 2 diambil secara acak sebagai nilai *centroid* awal yaitu data 4, 7, dan 9. Sehingga, *centroid* awal ditunjukkan pada Tabel 3.

Tabel 3. *Centroid* Awal

<i>Centroid</i>	R_corr	R_hom	R_cont	R_eng
1	0,994942	0,640498	42,27761	0,082310
2	0,996905	0,579667	21,69937	0,068690
3	0,988355	0,507189	106,2014	0,068514

Berdasarkan Tabel 3 proses *K-Means Clustering* akan mengcluster data citra ke dalam 3 *cluster*. Hitung jarak setiap data pada Tabel 2 terhadap nilai *centroid* awal pada Tabel 3 menggunakan rumus *Euclidean Distance*. Hasil perhitungan jarak data ke *centroid* awal ditunjukkan pada Tabel 4.

Tabel 4. Hasil Perhitungan Jarak Data ke *Centroid* Awal

Data	C1	C2	C3	Jarak Terdekat
1	16,22896	36,8065	47,69566	16,22896
2	10,00937	30,58764	53,91458	10,00937
3	58,58596	79,16416	5,338252	5,338252
4	0	20,57833	63,92391	0
5	14,03885	6,540466	77,96196	6,540466
6	45,02165	65,59976	18,90229	18,90229
7	20,57833	0	84,50203	0
8	12,74641	7,832344	76,67023	7,832344
9	63,92391	84,50203	0	0
10	7,711398	28,2897	56,21252	7,711398

Berdasarkan Tabel 4 jarak terdekat merupakan nilai paling kecil sebuah data terhadap *centroid*nya. Data yang memiliki jarak terdekat terhadap C1 yaitu 1, 2, 4, dan 10 dinyatakan sebagai anggota *cluster* 1. Data 5, 7, dan 8 dinyatakan sebagai anggota *cluster* 2, karena memiliki jarak terdekat terhadap C2. Sementara, data 3, 6, dan 9 merupakan anggota *cluster* 3 karena memiliki jarak terdekat terhadap C3.

Hitung *centroid* baru untuk *cluster* yang sudah terbentuk menggunakan rumus *centroid*. Sehingga didapat *centroid* baru ditunjukkan pada Tabel 5.

Tabel 5. *Centroid* Baru

<i>Centroid</i>	R_corr	R_hom	R_cont	R_eng
1	0,994216	0,596412	50,76482	0,083058
2	0,995269	0,574306	26,49002	0,085052
3	0,990496	0,533884	98,12133	0,077981


Hitung kembali jarak setiap data pada Tabel 2 terhadap nilai *centroid* baru pada Tabel 5 menggunakan rumus *Euclidean Distance*. Hasil perhitungan jarak setiap data ke *centroid* baru ditunjukkan pada Tabel 6.

Tabel 6. Hasil Perhitungan Jarak Data ke *Centroid* Baru

Data	C1	C2	C3	Jarak Terdekat
1	7,741863	32,01586	39,61566	7,741863
2	1,522654	25,79699	45,83449	1,522654
3	50,09871	74,37351	2,742471	2,742471
4	8,487327	15,78772	55,84383	8,487327
5	22,5256	1,750919	69,88192	1,750919
6	36,53435	60,8091	10,82225	10,82225
7	29,06546	4,790683	76,42198	4,790683
8	21,23363	3,042207	68,59015	3,042207
9	55,43663	79,71138	8,08009	8,08009
10	0,777008	23,49907	48,13244	0,777008

Tabel 6 memiliki nilai yang berbeda dengan Tabel 4, namun jika dilihat hasil *cluster* yang dibentuk sama yaitu data 1, 2, 4, dan 10 merupakan anggota dari cluster 1. Data 5, 7, dan 8 merupakan anggota dari cluster 2. Data 3, 6, dan 9 merupakan anggota cluster 3. Perhitungan akan dilakukan secara iteratif sampai tidak ada lagi data yang berpindah ke *cluster* lainnya.

Tahap selanjutnya menentukan jumlah *cluster* yang optimal menggunakan metode *elbow*. Metode ini menghitung nilai *Sum of Squared Error* (SSE) dalam *cluster* dan akan ditunjukkan dalam bentuk *plot*.



Gambar 5. Metode *Elbow*

Berdasarkan Gambar 5. jumlah *cluster* yang optimal adalah 3. Dimana pada angka 3 *plot* membentuk siku. Hasil *clustering* dari 900 data citra terbagi menjadi 3 *cluster* ditunjukkan pada Tabel 7.

Tabel 7. Hasil *Clustering*

<i>Cluster</i> (<i>d=2</i>)	DSH	DB	DKB	Jumla h	Akurasi		
1	150	11 7	214	481	31,19%	24,32%	44,49%
2	98	15 0	43	291	33,68%	51,54%	14,78%
3	52	33	43	128	40,62%	25,78%	33,60%

Keterangan:

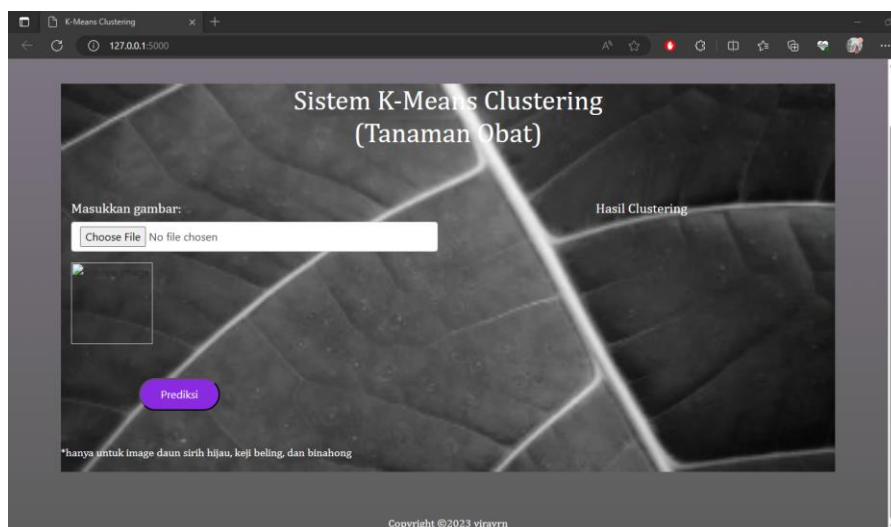
- DSH = Daun Sirih Hijau
- DB = Daun Binahong
- DKB = Daun Keji Beling

Hasil *clustering* citra dalam Tabel 7. Berdasarkan nilai fitur-fitur GLCM yang telah dihitung sebelumnya. Data citra dengan nilai fitur GLCM yang mirip ditempatkan dalam *cluster* yang sama, dan setiap *cluster* memiliki ciri khasnya sendiri. Akurasi menunjukkan persentase keberhasilan dalam pengelompokkan. Tabel 7. menunjukkan *cluster* 1 memiliki kesamaan nilai

fitur yang lebih tinggi pada citra daun keji beling, sehingga citra daun keji beling lebih dominan dalam *cluster* tersebut. Hal yang sama berlaku untuk *cluster 2* dengan citra daun binahong dan *cluster 3* dengan citra daun sirih hijau.

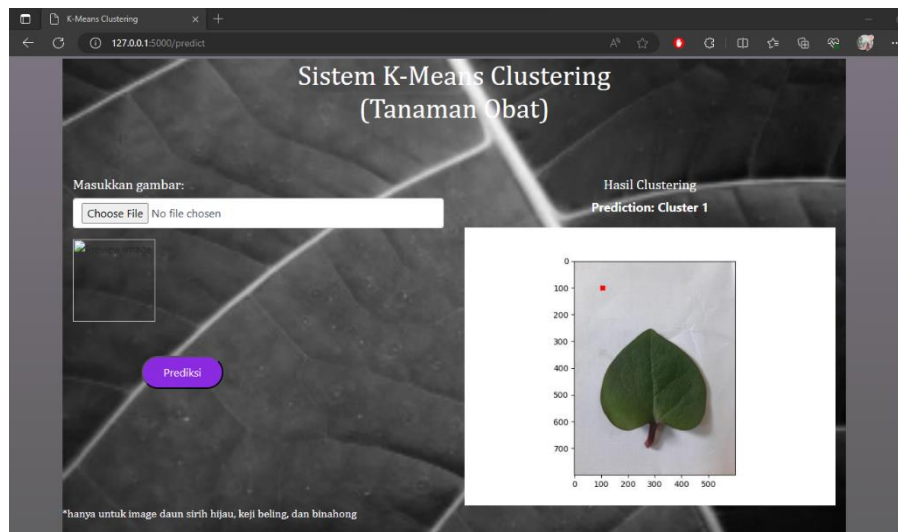
3.4 Pengembangan Sistem

Pengembangan sistem merupakan implementasi *K-Means Clustering* ke dalam sistem berbasis *web* menggunakan *tools VSCode* dan *web framework flask* dalam *python*. Cara kerja sistem yaitu saat citra diinputkan, sistem akan mengekstraksi nilai fitur-fitur pada citra. Berdasarkan nilai tersebut citra akan diprediksi *clusternya* berdasarkan *centroid* terdekat oleh sistem.



Gambar 6. Tampilan Awal Sistem

Hasil prediksi *cluster* akan ditampilkan ditunjukkan pada Gambar 7.



Gambar 7. Tampilan Hasil *Clustering*

4. KESIMPULAN

Kesimpulan dari penerapan *K-Means Clustering* untuk citra tanaman obat adalah:

1. Metode *K-Means* dapat meng*clustering* citra tanaman obat. Tetapi, hasil *clustering* belum cukup baik karena penentuan nilai *centroid* berpengaruh terhadap hasil *cluster*.
2. Implementasi sistem *K-Means Clustering* untuk citra tanaman obat berhasil dilakukan dengan tampilan hanya 1 halaman *web*.

5. SARAN

Saran yang diberikan untuk penelitian selanjutnya adalah:

1. Untuk meningkatkan hasil *clustering*, dapat dilakukan dengan menambahkan lebih banyak data citra daun pada *dataset*.
2. Agar hasil *clustering* menjadi lebih baik, ekstraksi fitur dapat diperluas dengan menggabungkan metode seperti HSV, RGB, dan Deteksi Tepi dalam proses analisis citra.
3. Untuk meningkatkan interaktivitas sistem, dapat mengembangkan sistem dengan menambahkan berbagai fitur tambahan.

DAFTAR PUSTAKA

- [1] M. Yassir and A. Asnah, "Pemanfaatan Jenis Tumbuhan Obat Tradisional Di Desa Batu Hampan Kabupaten Aceh Tenggara," *Biot. J. Ilm. Biol. Teknol. dan Kependidikan*, vol. 6, no. 1, p. 17, 2019, doi: 10.22373/biotik.v6i1.4039.
- [2] R. Widodo, A. W. Widodo, and A. Supriyanto, "Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) Citra Buah Jeruk Keprok (*Citrus reticulata* Blanco) untuk Klasifikasi Mutu," *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 2, no. 11, pp. 5769–5776, 2018, [Online]. Available: <https://j-ptiik.ub.ac.id/index.php/j-ptiik/article/view/3420>
- [3] D. A. C. Rachman, R. Goejantoro, and F. D. T. Amijaya, "Implementasi Text Mining Pengelompokan Dokumen Skripsi Menggunakan Metode K-Means Clustering," *J. EKSPONENSIAL*, vol. 11, no. 2, pp. 167–174, 2020.
- [4] S. Desmanto and R. Angreni, "Penerapan Algoritma K-Means Clustering Untuk Pengelompokan Citra Digital Dengan Ekstraksi Fitur Warna RGB," *Julyxxxx*, vol. x, No.x, no. x, pp. 1–5, 2014.
- [5] A. Atina, "Segmentasi Citra Paru Menggunakan Metode k-Means Clustering," *J. Pendidik. Fis. dan Keilmuan*, vol. 3, no. 2, p. 57, 2017, doi: 10.25273/jpfk.v3i2.1475.
- [6] S. Sarno, "Pemanfaatan Tanaman Obat (Biofarmaka) Sebagai Produk Unggulan Masyarakat Desa Depok Banjarnegara," *Abdimas Unwahas*, vol. 4, no. 2, pp. 73–78, 2019, doi: 10.31942/abd.v4i2.3007.
- [7] S. I. Astuti, S. P. Arso, and P. A. Wigati, "Perbandingan Algoritma K-Means Dan Algoritma K-Medoids Dalam Pengelompokan Komoditas Tanaman Biofarmaka Di Provinsi Jawa Tengah Tahun 2018," 2018.
- [8] S. Jatmika and D. Purnamasari, "Rancang Bangun Alat Pendeteksi Kematangan Buah Apel Dengan Menggunakan Metode Image Processing Berdasarkan Komposisi Warna," *J. Ilm. Teknol. Inf. Asia*, vol. 8, no. 1, pp. 51–58, 2014.
- [9] M. Widyaningsih, "Identifikasi Kematangan Buah Apel Dengan Gray Level Co-Occurrence Matrix (GLCM)," *J. SAINTEKOM*, vol. 6, no. 1, p. 71, 2017, doi: 10.33020/saintekom.v6i1.7.
- [10] E. Retnoningsih and R. Pramudita, "Mengenal Machine Learning Dengan Teknik Supervised Dan Unsupervised Learning Menggunakan Python," *Bina Insa. Ict J.*, vol. 7, no. 2, p. 156, 2020, doi: 10.51211/biict.v7i2.1422.
- [11] R. Irsyad, "Penggunaan Python Web Framework Flask Untuk Pemula," *Lab. Telemat. Sekol. Tek. Elektro Inform.*, pp. 1–4, 2018.