



Implementasi Algoritma *K-Medoid* pada *Clustering* Sayuran Unggulan di Kabupaten Aceh Utara

Rini Meiyanti^{*1}, Muhammad Muaz Munauwar², Rahma Fitria³, Hafizh Al Kautsar Aidilof⁴

^{*1,4} Program Studi Teknik Informatika, Universitas Malikussaleh, Aceh, Indonesia

² Program Studi Agroekoteknologi, Universitas Malikussaleh, Aceh, Indonesia

³ Program Studi Sistem Informasi, Universitas Malikussaleh, Aceh, Indonesia

*Email Penulis Korespondensi: rinimeiyanti@unimal.ac.id

Abstrak

Klasterisasi tanaman pada kelompok tani adalah proses pengelompokan tanaman berdasarkan karakteristik tertentu, seperti jenis tanaman, musim tanam, atau lokasi geografis, dengan tujuan meningkatkan efisiensi produksi. Kelompok Tani KWT Meugah Raya masih belum mampu melebihi hasil produksi pertanian sayuran di Aceh Utara. Metode data mining dapat mengidentifikasi pola-pola menarik dalam kumpulan data, salah satunya adalah algoritma K-Medoids clustering yang mengelompokkan data berdasarkan kesamaan karakteristik. Cluster terbentuk dengan menghitung sejauh mana kedekatan antara medoid dan objek non-medoids. Data yang digunakan adalah data dari Badan Pusat Statistik (BPS) pada tahun 2021-2023 di Kabupaten Aceh Utara mengumpulkan data dari 5 kategori sayuran dan 4 variabel, meliputi luas panen, produksi, luas tanaman, dan luas penanaman baru. Melalui algoritma K-Medoids, hasil klastering sayuran unggulan menghasilkan pengelompokan potensi ke dalam 3 klaster, yaitu klaster rendah (C1), sedang (C2), dan tinggi (C3) dengan mengumpulkan macam-macam data sayuran yang ditanam oleh masyarakat setempat berupa cabai besar, kacang panjang, kangkung, terong dan tomat. Langkah berikutnya adalah Menentukan nilai titik pusat awal dengan menyusun data berdasarkan urutan dari yang terendah hingga tertinggi pada setiap data variabel, berdasarkan keseluruhan data yang tersedia. Berdasarkan hasil penelitian ini, metode K-Medoids terbukti sangat efektif dalam melakukan clustering pada data hasil panen tanaman hortikultura. Evaluasi kinerja algoritma dilakukan dengan memanfaatkan Davies-Bouldin Index (DBI) sebagai metode evaluasi, dilakukan pengukuran untuk menilai kualitas pengelompokan yang dihasilkan. Setelah proses evaluasi menggunakan DBI selesai, algoritma K-Medoids memperoleh nilai 0,5537744324187953.

Kata kunci—Tanaman Sayuran, K-Medoids, Kelompok Tani

Abstract

Crop clustering in farmer groups is the process of grouping crops based on certain characteristics, such as crop type, growing season, or geographic location, with the aim of increasing production efficiency. The Meugah Raya KWT Farmer Group is still unable to exceed

the agricultural production of vegetables in North Aceh. Data mining methods can identify interesting patterns in a data set, one of which is the K-Medoids clustering algorithm that groups data based on similar characteristics. Clusters are formed by calculating the extent of closeness between medoids and non-medoids objects. The data used is data from the Central Statistics Agency (BPS) in 2021-2023 in North Aceh District collecting data from 5 vegetable categories and 4 variables, including harvest area, production, crop area, and new planting area. Through the K-Medoids algorithm, the results of clustering superior vegetables produce potential groupings into 3 clusters, namely low (C1), medium (C2), and high (C3) clusters by collecting various kinds of vegetable data grown by the local community in the form of large chili peppers, long beans, kankung, eggplant and tomatoes. The next step is to determine the value of the initial center point by arranging the data based on the order from lowest to highest in each variable data, based on all available data. Based on the results of this study, the K-Medoids method proved to be very effective in clustering data on horticultural crop yields. Evaluation of algorithm performance is done by utilizing Davies-Bouldin Index (DBI) as an evaluation method, measurements are taken to assess the quality of the resulting clustering. After the evaluation process using DBI was completed, the K-Medoids algorithm obtained a value of 0.5537744324187953.

Keywords—Vegetable Crops, K-Medoids, Farmer Group

1. PENDAHULUAN

Kelompok tani dihadapkan pada berbagai kendala, termasuk produktivitas yang rendah, kualitas produk yang buruk, dan keuntungan yang rendah dari hasil panen mereka. Hal ini, pada gilirannya, disebabkan oleh berbagai masalah, termasuk kurangnya pengetahuan teknis, penggunaan varietas unggul, penggunaan input yang tidak efisien atau tidak optimal, praktik pengelolaan pertanian yang buruk, dan praktik pascapanen yang buruk [1]. Selain itu, petani juga kekurangan informasi tentang harga dan pasar, serta menghadapi kendala kelembagaan dan infrastruktur yang menyebabkan tingginya biaya transaksi dan ketidakmampuan untuk mengakses pasar, terutama pasar yang bernilai tinggi. Dengan demikian, petani terlewatkan dari peluang yang muncul dari globalisasi dan permintaan konsumen yang berubah dengan cepat [2]-[3].

Dalam melestarikan tanaman hortikultura yang merupakan bagian dari agribisnis yang memberi manfaat ekonomi dan menjadi salah satu mata pencaharian bagi masyarakat dan petani kecil di setiap daerah [4]. Kelompok tani adalah wadah bagi petani yang berkumpul untuk mencapai berbagai tujuan bersama dalam bidang pertanian [5]-[6]. Dalam *data mining*, salah satu metode yang dikenal adalah *clustering*, yang digunakan untuk mengelompokkan data menurut pola atau fitur tertentu [7]. Dalam penelitian [8] dikatakan bahwa sebagai salah satu teknik dalam *clustering*, K-Medoids digunakan untuk memperoleh nilai *k-cluster* dengan memilih data yang paling dekat dengan item dalam kumpulan informasi yang ada. Dalam pengelompokan data, K-Medoids digunakan untuk membagi informasi menjadi kategori-kategori berdasarkan perhitungan objek berukuran kecil, dengan tujuan mencari titik pusat yang lebih akurat [9]-[10].

Dengan melihat semua faktor secara menyeluruh, kelompok tani dapat memilih jenis sayuran unggulan yang memiliki potensi untuk berkembang dan memberikan keuntungan yang besar bagi anggotanya. Berdasarkan informasi yang dihimpun dari Dinas Pertanian dan Ketahanan Pangan serta Badan Pusat Statistik Kabupaten Aceh Utara, hasil pertanian di daerah tersebut meliputi berbagai jenis sayuran, dengan data terkait luas panen, luas tanaman, luas penanaman baru, dan hasil produksi (dalam Kwintal). Pada penelitian ini dilakukan pengelompokan data sayuran unggulan di Kabupaten Aceh Utara, yang didasarkan pada hasil potensi pertanian, dapat dilakukan dengan menggunakan Algoritma K-Medoids untuk memudahkan pemerintah daerah dan masyarakat dalam memanfaatkannya, khususnya Kelompok Tani KWT Meugah Raya. Penelitian ini bertujuan untuk mengevaluasi komoditas yang berpotensi dalam Kelompok Tani, di mana tanaman yang memiliki potensi besar akan dipelihara dan

diproduksi lebih banyak, sementara tanaman dengan hasil rendah akan menjadi prioritas untuk perbaikan. Oleh karena itu, metode *data mining* diperlukan untuk melakukan teknik pengelompokan.

2. METODE PENELITIAN

2.1 Metode Dalam Data Mining

Pembagian metode *data mining* dibagi menjadi beberapa kelompok [11], sebagai berikut:

1. Penjelasan mengenai metode *data mining* ini bertujuan untuk menggali pemahaman yang lebih mendalam tentang data yang diperoleh. Tujuan akhirnya adalah untuk mengidentifikasi pola atau perilaku yang terkandung dalam data tersebut.
2. Estimasi/prediksi metode yang menggunakan data dengan target data dengan variabel-variabel yang berisi numerik.
3. Klasifikasi algoritma yang menggunakan data *Supervised Learning* (memiliki label) dengan target berupa nilai kategori. Algoritma yang sering dipakai untuk memecahkan permasalahan klasifikasi adalah *Naive bayes*, *K-Nearest Neighbor*, *C4.5*, maupun *ID3*.
4. Klastering pengelompokan data *unsupervised learning* berdasarkan kelas yang mirip antara satu dan yang lain, dan memiliki perbedaan dengan klaster-klaster yang lain tanpa memiliki variabel target. Algoritma yang sering digunakan adalah *K-Means*, *K-Medoids*, *SOM*, *Fuzzy C-means*.

2.2 Clustering

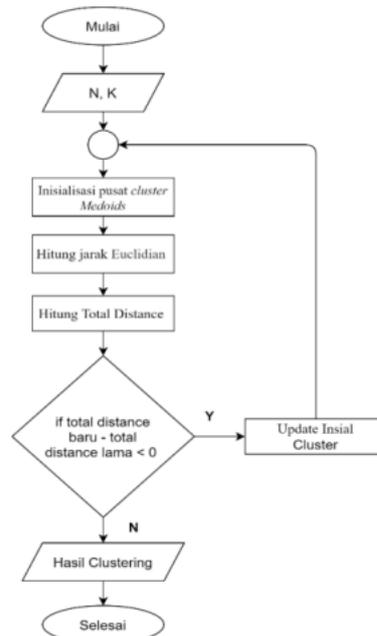
Clustering adalah teknik untuk membagi data ke dalam kelompok-kelompok, di mana setiap kelompok terdiri dari individu atau objek yang memiliki kesamaan berdasarkan matriks tertentu. Analisis klaster berfungsi untuk mengelompokkan individu atau objek ke dalam beberapa kelompok dengan karakteristik yang berbeda antar kelompok, sementara dalam kelompok yang sama, sifatnya akan relatif homogen [12]-[13]. Dalam *data mining*, *clustering* adalah teknik untuk mengelompokkan data tanpa memperhatikan kelas data tertentu. Metode klasterisasi ini dapat digunakan untuk memberi label pada data yang kelasnya belum terdefinisi [14].

Klastering dapat diartikan sebagai teknik pengelompokan data yang digunakan di berbagai bidang, termasuk pemasaran, analisis masalah bisnis, segmentasi pasar, prediksi pola dalam visi komputer, zonasi wilayah, identifikasi objek, serta pengolahan citra [15]. Klastering digunakan untuk mencapai berbagai tujuan seperti mengelompokkan data kemiskinan di provinsi Banten yang bertujuan untuk mengetahui daerah dengan tingkat kemiskinan tinggi, sedang, dan rendah [11]. Klastering juga digunakan untuk tujuan mengetahui daerah dengan hasil ikan yang tinggi, sedang maupun rendah di Jawa Timur [14]. Pada masa pandemi, klastering dapat digunakan untuk menganalisis dan menentukan area yang memiliki kemungkinan besar dalam penyebaran virus Corona, yang bertujuan untuk mengidentifikasi daerah-daerah dengan potensi risiko tinggi terhadap pandemi Covid-19 di Indonesia [16].

2.3 K-Medoids

K-Medoids, atau yang dikenal dengan nama PAM (*Partitioning Around Medoid*), merupakan algoritma yang dikembangkan oleh Leonard Kaufman dan Peter J. Rousseeu. Algoritma ini serupa dengan *K-Means*, tetapi keduanya membagi data menjadi beberapa kelompok menggunakan metode yang berbeda. Algoritma *K-Medoids* bertujuan untuk menentukan pusat setiap *cluster*. Berbeda dengan *K-Means* yang menggunakan rata-rata sebagai titik pusat, *K-Medoids* memilih objek dalam setiap kelompok sebagai medoid untuk menjadi pusat *cluster*. Algoritma *K-Medoids* dirancang untuk mengatasi masalah pada *k-median* yang rentan terhadap *outlier*, di mana objek yang jauh dari mayoritas data dapat memengaruhi perhitungan rata-rata, sehingga mengarah pada distorsi hasil pengelompokan. Dalam algoritma *K-Medoids* [17] rata-rata *cluster* berfungsi sebagai strategi untuk membagi data, karena menggunakan objek yang terpilih (*medoids*) sebagai pusat *cluster* berdasarkan perhitungan rata-

rata dari objek-objek dalam *cluster* tersebut. Adapun alur dalam melakukan proses *clustering* data menggunakan algoritma *K-Medoids* dapat dilihat pada Gambar 1 [18].



Gambar 1 Proses *Clustering K-Medoids*

Keterangan:

1. Inisialisasi dilakukan dengan menentukan jumlah pusat *cluster* K .
2. Manfaatkan persamaan *Euclidean Distance* untuk mengelompokkan setiap data (objek) ke dalam *cluster* yang terdekat dengan contoh, menggunakan persamaan (1).

$$d_{ij} = \sqrt{\sum_{a=1}^p (x_{ia} - x_{ja})^2} = \sqrt{(X_i - X_j)' (X_i - X_j)} \dots \dots \dots (1)$$

Keterangan:

$i: 1, \dots, n;$

$j: 1, \dots, n$ dan p merupakan banyaknya *variable*

V : yaitu matrik varian kovarian.

3. Pilihlah objek secara acak dari setiap *cluster* untuk dijadikan *medoids* yang baru.
4. Manfaatkan *medoid* yang baru untuk menghitung jarak setiap objek dengan anggota dalam *cluster*.
5. Total deviasi (S) dihitung dengan membandingkan jarak baru dengan jarak sebelumnya. Jika nilai $S < 0$, objek tersebut akan ditukar dengan data *cluster* lain untuk membentuk himpunan baru dari k objek yang berfungsi sebagai *medoids*.
6. Ulangi langkah 3 hingga 5 hingga *medoid* tidak berubah lagi untuk memperoleh kelompok *cluster* yang stabil juga sesuai.

Dibandingkan dengan *K-Means*, algoritma *K-Medoids* lebih rentan secara komputasi karena perhitungan *medoid* bergantung pada frekuensi objek yang terjadi dalam *dataset*. Karakteristik *K-Medoids* mencakup pusat *cluster* yang termasuk dalam data yang terindeks itu sendiri. Algoritma *K-Medoids* yang baru diperkenalkan beroperasi serupa dengan *K-Means*, namun diuji dengan metode yang berbeda untuk menentukan *medoids* [19]. *RapidMiner* dapat dimanfaatkan sebagai alat untuk penambangan data, penambangan teks, dan analitik terkini, dengan mengaplikasikan pendekatan deskriptif dan prediktif untuk menyajikan informasi yang membantu pengguna dalam menarik kesimpulan yang lebih tepat. *Rapid Miner* menyediakan sekitar 500 operator untuk penambangan informasi, yang mencakup input, *reasoning*, pemrosesan data, dan instruksi tampilan. *Rapid Miner* dibangun dengan bahasa pemrograman *Python*, sehingga dapat dijalankan pada berbagai versi perangkat lunak.

2.4 Evaluasi Kinerja Algoritma Menggunakan DBI

Komparasi kinerja clustering *K-Medoids* menggunakan *Davies Bouldin Index* (DBI) sebagai indikator evaluasi. Mengacu pada studi yang dilakukan oleh Singh [20], DBI unggul dalam menilai kualitas *cluster*, karena mempertimbangkan kohesi (kedekatan data dengan *centroid*) dan separasi (jarak antar *centroid* antar *cluster*). Semakin kecil nilai DBI yang didapat, semakin baik kualitas *clustering* yang dihasilkan. Proses perhitungan DBI dimulai dengan menghitung *sum of square within cluster* (SSW), yang digunakan untuk mengukur kohesi dalam *cluster* ke-*i* yang dirumuskan pada Persamaan (2).

$$SSW_i = \frac{1}{m_i} \sum_{j=1}^{m_i} d(x_j, c_i) \quad (2)$$

Keterangan:

SSW : *Sum of Squere within Cluster*.

m_i : Jumlah data yang terdapat pada *cluster* ke- *i*.

c_i : *Centroid Cluster* ke-*i*.

$d(x_i, c_j)$: Jarak data ke-*i* menuju titik *cluster* *i*.

Selanjutnya, langkah berikutnya dilakukan dengan menggunakan Persamaan (3) untuk mengukur jarak antar *cluster*.

$$SSB_{ij} = d(i, j) \quad (3)$$

Keterangan:

SSB : *Sum of Squere between Cluster*.

$d(i, j)$: Jarak *Euclidiene Distance* data ke-*i* dan data ke-*j*.

Selanjutnya, yaitu mencari rasio dari hasil perhitungan SSW dan SSB seperti pada Persamaan (4).

$$R_{ij} = \frac{SSW_i + SSW_j}{SSB_{ij}} \quad (4)$$

Untuk proses perhitungan tahap akhir, Persamaan (5) digunakan untuk memperoleh nilai DBI.

$$DBI = \frac{1}{k} \sum_{i=1}^k \max_{i \neq j} (R_{ij}) \quad (5)$$

Keterangan:

k : Jumlah *cluster* yang dihitung.

Nilai DBI yang semakin kecil, baik mendekati 0 atau nilai yang sama dengan 0, menunjukkan bahwa pengelompokan menghasilkan *cluster* yang lebih baik. DBI dihitung dengan Algoritma *K-Medoids*, nilai DBI ini digunakan untuk mengevaluasi kinerja klusterisasi.

3. HASIL DAN PEMBAHASAN

3.1 Data Sayuran Cabai Besar

Bagian ini berisi perhitungan dan implementasi algoritma *K-Medoids* yang diperlukan untuk proses pengelompokan dalam produktivitas sayuran unggulan di beberapa Kecamatan di Aceh Utara. Pada Penelitian ini, data yang digunakan merupakan data yang diperoleh langsung dari BPS Aceh Utara. Penelitian ini mengolah data mengenai lima kategori sayuran, seperti yang terlihat pada Gambar 2, dari periode 2021 hingga 2023, yang mencakup 23 kecamatan di Kabupaten Aceh Utara, untuk dikelompokkan dalam *clustering*. Pada perhitungan ini, Algoritma *K-Medoids* diimplementasikan menggunakan bahasa pemrograman *Python*.

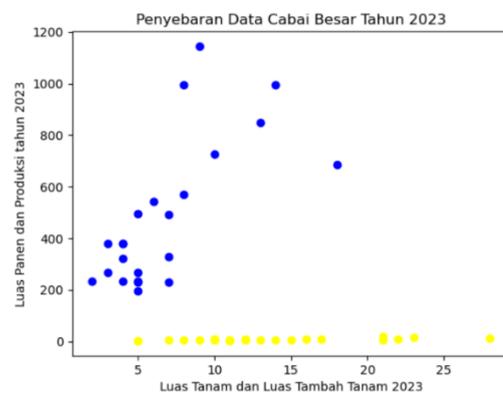
```

#Mengambil tiap coloumn dan menjadikan data awal untuk tahun 2023
x = df['Luas Tanam (Ha) 2023']
y = df['Luas Panen (Ha) 2023']
a = df['Luas Tambah Tanam (Ha) 2023']
b = df['Produksi (Kw) 2023']
plt.scatter(x,y,color='yellow')
plt.scatter(a,b,color='blue')
#Sumbu y
plt.ylabel("Luas Panen dan Produksi tahun 2023")
#sumbu x
plt.xlabel("Luas Tanam dan Luas Tambah Tanam 2023")
plt.title("Penyebaran Data Cabai Besar Tahun 2023")
plt.show()

```

Gambar 2 Gambar Data awal Cabai Besar Tahun 2023

Gambar 3 merupakan sebagian data yang di tampilkan dari *dataset*. Data tersebut yang nantinya akan di pakai untuk melakukan perhitungan sayuran unggulan pada kecamatan yang ada di Aceh Utara.



Gambar 3 Penyebaran Data Cabai Besar Tahun 2021

```

# Normalizing the data
scaler = MinMaxScaler()
features_2021_scaled = scaler.fit_transform(features_2021)
features_2022_scaled = scaler.fit_transform(features_2022)
features_2023_scaled = scaler.fit_transform(features_2023)
print(features_2021_scaled)
print(features_2022_scaled)
print(features_2023_scaled)

```

Gambar 4 Normalisasi Data

Gambar 4, merupakan proses normalisasi data pada nilai kriteria yang ada di dalam *dataset*. Normalisasi data bertujuan untuk menyamakan skala berbagai kriteria agar dapat dibandingkan secara langsung sehingga dapat dievaluasi secara adil saat proses perhitungan selanjutnya.

```

data2023 = {
  'Kecamatan': ['BATAHAN', 'SINUNUKAN', 'BATANG NATAL', 'LINGGA BAYU', 'RANTO BAEK',
               'KOTAPAN', 'ULU PUNGKUT', 'TAMBANGAN', 'LEMBAR SULAMPI', 'PUCARK SULAMPI',
               'MUARA SIAMBANG', 'PAKANTA', 'PANYABUNGAN BARAT', 'PANYABUNGAN UTARA',
               'PANYABUNGAN SELATAN', 'PANYABUNGAN TIMUR', 'PANYABUNGAN', 'HUTA BARGOT',
               'NATAL', 'MUARA BATANG GADIS', 'SIAU', 'BUKIT MALINTANG', 'NAGA JUANG'],
  'Luas Tanam': [23, 18, 18, 18, 16, 26, 14, 20, 18, 24, 14, 14, 13, 13, 13, 19, 29, 17, 24, 12, 104, 6, 16],
  'Luas Panen': [17, 9, 12, 8, 7, 10, 8, 13, 12, 18, 9, 10, 9, 8, 12, 12, 18, 12, 10, 5, 73, 5, 14],
  'Luas Tambah Tanam': [16, 9, 13, 8, 7, 10, 12, 12, 12, 15, 9, 10, 8, 8, 12, 10, 19, 12, 10, 7, 73, 5, 12],
  'Produksi (Ton)': [937, 468, 527, 438, 416, 429, 715, 715, 715, 1054, 429, 429, 468, 468, 468, 715, 937, 234, 514,

```

Gambar 5 Gambar Penentuan Alternatif dan Kriteria

Gambar 5 merupakan tahap penentuan alternatif dan kriteria, yang mana setiap kecamatan yang ada pada *dataset* ditetapkan sebagai alternatif yang nantinya akan di rangkingkan. Sementara, untuk kriteria perhitungannya di peroleh dari luas tanam, luas panen, luas tambah tanam, dan produksi dari ke 5 sayuran yang di tanam pada masing masing kecamatan.

```
n_clusters = 3
kmedoids = KMedoids(n_clusters=n_clusters, random_state=42)
kmedoids.fit(X)
```

KMedoids

KMedoids(n_clusters=3, random_state=42)

Gambar 6 Inisialisasi dan fitting model K-Medoids

Tampilan tabel hasil pengelompokan menggunakan *K-medoids* di Python berfungsi untuk memberikan gambaran yang jelas mengenai bagaimana data dikelompokkan seperti Tabel 1. Sedangkan Tabel 2 merupakan data hasil sayuran unggulan.

Tabel 1 Tabel Kluster Cabai Besar

	Kecamatan	Luas Tanam	Luas Panen	Luas Tambah Tanam	Produksi (Ton)	Cluster
0	BATAHAN	23	17	16	937	2
1	SINUNUKAN	18	9	9	468	0
2	BATANG NATAL	18	12	13	527	0
3	LINGGA BAYU	18	8	8	430	0
4	RANTO BAEK	16	7	7	416	0
5	KOTAPAN	26	10	10	429	0
6	ULU PUNGKUT	14	8	12	715	2
7	TAMBANGAN	20	13	12	715	2
8	LEMBAR SULAMPI	18	12	12	715	2
9	PUCARK SULAMPI	24	18	15	1054	2
10	MUARA SIAMBANG	14	9	9	429	0
11	PAKANTA	14	10	10	429	0
12	PANYABUNGAN BARAT	13	9	8	468	0
13	PANYABUNGAN UTARA	13	8	8	468	0
14	PANYABUNGAN SELATAN	13	12	12	468	0
15	PANYABUNGAN TIMUR	19	12	10	715	2
16	PANYABUNGAN	29	18	19	937	2
17	HUTA BARGOT	17	12	12	234	1

Tabel 2 Data hasil Sayuran Unggulan

No	Kecamatan	Tahun 2023			
		Cabai Besar			
		Luas Tanam (Ha)	Luas Panen (Ha)	Luas Tambah Tanam (Ha)	Produksi (Kw)
1	Baktiya	23	17	16	937
2	Banda Baro	18	9	9	468
3	Cot Girek	18	12	13	527
4	Cot Girek	18	8	5	430
5	Dewantara	17	8	7	416

6	Geureungdong pase	26	10	10	429
7	Kuta Makmur	11	8	8	429
8	Langkahan	20	13	12	715
9	Lapangan	21	12	12	715
10	Lhoksukon	30	27	15	1054
11	Matangkuli	9	8	7	497
12	Muara Batu	14	10	10	622
13	Meurah Mulia	30	14	13	622
14	Nibong	14	9	8	353
15	Nisam	19	12	12	468
16	Paya Bakong	19	12	12	468
17	Samudera	28	22	15	864
18	Sawang	7	5	5	234
19	Seunudon	24	10	10	514
20	Simpang Keramat	10	7	7	325
21	Syamtalira aron	104	73	73	3630
22	Tanah Pasir	6	5	5	125
23	Tanah Luas	16	14	12	546

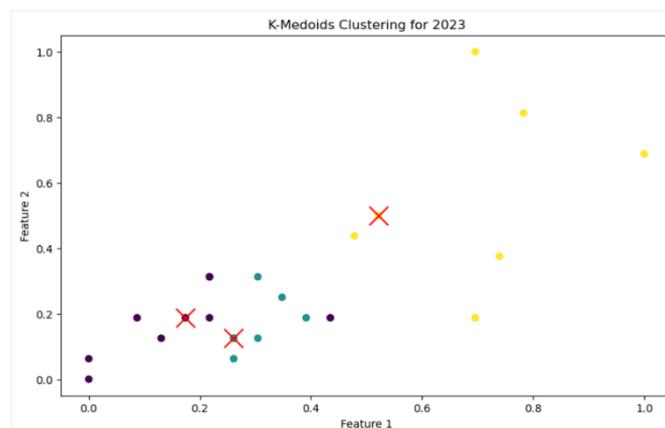
3.2 Hasil Kluster dengan K-Medoid

Tabel 3 merupakan tabel hasil akhir dari pengelompokan jenis sayuran cabai besar yang di Kecamatan Aceh Utara dengan menggunakan Algoritma *K-Medoids*.

Tabel 3 Hasil akhir Kluster K-Medoid tanaman Cabai

No	Kecamatan	Clusters	Tahun
1	Baktiya	0	2023
2	Banda Baro	1	2023
3	Cot Girek	1	2023
4	Cot Girek	2	2023
5	Dewantara	2	2023
6	Geureungdong pase	1	2023
7	Kuta Makmur	2	2023
8	Langkahan	1	2023
9	Lapangan	1	2023
10	Lhoksukon	0	2023
11	Matangkuli	2	2023
12	Muara Batu	2	2023

13	Meurah Mulia	1	2023
14	Nibong	2	2023
15	Nisam	1	2023
16	Paya Bakong	1	2023
17	Samudera	0	2023
18	Sawang	2	2023
19	Seunudon	1	2023
20	Simpang Keramat	2	2023
21	Syamtalira aron	0	2023
22	Tanah Pasir	2	2023
23	Tanah Luas	1	2023



Gambar 4 Hasil Sistem Pada Tanaman Cabai Tahun 2023

Dari Gambar 4, terlihat ada beberapa *cluster* yang diwakili oleh warna yang berbeda. Setiap warna menunjukkan kelompok (*cluster*) yang berbeda dari data tanaman cabai. Titik dengan tanda silang merah besar menunjukkan *medoid* dari setiap *cluster*. *Medoid* adalah titik pusat dari *cluster* yang paling dekat dengan semua titik lain di dalam *cluster* tersebut. Data tanaman cabai tampaknya tersebar dalam beberapa *cluster*, dengan sebagian besar data berkumpul di bagian kiri bawah grafik, menunjukkan bahwa sebagian besar tanaman memiliki nilai yang relatif rendah untuk kedua fitur yang ditampilkan di sumbu X (*Feature 1*) dan Y (*Feature 2*). Ada satu titik data di bagian kanan atas grafik yang tampaknya jauh dari semua *cluster* lainnya. Ini mungkin menunjukkan *outlier*, yang merupakan titik data yang sangat berbeda dari titik-titik lain dalam *dataset*. Secara keseluruhan, gambar ini menunjukkan bagaimana data tanaman cabai dikelompokkan menjadi beberapa *cluster* yang berbeda berdasarkan fitur yang diukur, dengan *medoid* sebagai representasi dari pusat *cluster* tersebut. *Outlier* menunjukkan bahwa ada beberapa tanaman cabai yang memiliki karakteristik yang sangat berbeda dibandingkan dengan yang lain.

```
df['clusters'] = clusters_2023
features_2023 = df[['Luas Tanam (Ha) 2023', 'Luas Panen (Ha) 2023', 'Luas Tambah Tanam (Ha) 2023', 'Produksi (Kw) 2023'],
dbiscore = davies_bouldin_score(features_2023, features_2023['clusters'])
print(f"Hasil DBI Score Cabai besar 2023 {dbiscore}")
features_2023
```

Gambar 5 Hasil Sistem Pada Tanaman Cabai Tahun 2023

Gambar 5 menunjukkan metode evaluasi Algoritma *K-Medoids* menggunakan *Davies Bouldin Index* (DBI), yaitu menilai sejauh mana kualitas pengelompokan data dalam proses klusterisasi. Semakin kecil nilai DBI, semakin baik kualitas pengelompokan yang dihasilkan. Pada hasil *output*, didapatkan hasil *DBI Score* Cabai besar tahun 2023 adalah 0,5537744324187953. Semakin mendekati angka 0, semakin menunjukkan kualitas *clustering* data yang sangat baik. Nilai yang lebih kecil menandakan hasil *clustering* data yang semakin optimal. Dengan demikian, dapat disimpulkan bahwa model *clustering* yang diterapkan pada *source code* ini berhasil memberikan hasil yang memadai dalam mengelompokkan data sayuran unggulan di Aceh Utara.

4. KESIMPULAN

Penelitian ini menunjukkan bahwa hasil analisis perhitungan nilai rata-rata evaluasi kluster menggunakan *Indeks Davies-Bouldin* (DBI) *Score* cabai besar tahun 2023 adalah 0,5537744324187953. Penelitian ini juga berhasil mengkluster data hasil sayuran unggulan menjadi tiga kluster, yaitu tinggi atau C1 dengan persentase senilai 32%. Kluster sedang atau C2 dengan nilai persentase 30%. Kluster rendah atau C3 dengan nilai persentase 38%. Hasil ini juga menunjukkan bahwa metode *K-Medoid* sangat efektif dalam melakukan clustering pada data hasil panen tanaman hortikultura. Selain pencariannya algoritma lebih optimal dibandingkan dengan *K-Means* yang dapat memakan waktu lebih lama.

5. SARAN

Peneliti menyarankan untuk mengkombinasikan algoritma *K-Medoid* dengan algoritma lainnya agar mendapatkan hasil yang lebih optimal juga proses pencarian yang tidak sulit dan memakan waktu yang lama.

UCAPAN TERIMA KASIH

Penulis ingin menyampaikan rasa terima kasih yang mendalam kepada Tim Redaksi Jurnal Teknik Politeknik Negeri Sriwijaya atas dukungan dan kesempatan yang diberikan, yang memungkinkan artikel ilmiah ini untuk diproses dan diterbitkan. Terima kasih juga atas perhatian dan kerja sama yang telah diberikan sepanjang proses penerbitan ini.

DAFTAR PUSTAKA

- [1] Firdaus, F., & Suharyon, S.(2019). Kinerja Kelompok Tani Dalam Sistem Usaha tani Padi Lahan Rawa Dan Metode Pemberdayaannya: Studi Kasus Pada Kegiatan Padi Sawah Di Lahan Sub Optimal Kabupaten Tanjung Jabung Barat Jambi. *Jurnal Ilmiah Ilmu Terapan Universitas Jambi (JIITUJ)*, 3(2), 162-169.
- [2] Sutriani, N. W., Arimbawa, P., & Abdullah, S. (2018). Tingkat Kinerja Penyuluh pada Kelompok Tani Padi Sawah di Desa Bumi Raya Kecamatan Andoolo Kabupaten Konawe Selatan. *Jurnal Ilmiah Membangun Desa dan Pertanian*. 3(5), 133-137.
- [3] Jatmika, R. T. D., & Dewi, G. A. (2020). PENGARUH Kepemimpinan Dan Motivasi Terhadap Kinerja Kelompok Tani Padi Pandanwangi (Studi Kasus Di Desa Tegalega Kecamatan Warungkondang Kabupaten Cianjur). *AGRITA*, 1(2), 113-136.
- [4] BPS. (2023). Statistik Tanaman Hortikultura Provinsi Aceh 2023. Badan Pusat Statistik Provinsi Aceh.
- [5] Mutmainna, I., Hakim, L., & Saleh, D. (2016). Pemberdayaan kelompok tani di kecamatan marioriwawo kabupaten soppeng. *Jurnal Administrasi Publik*. 2(2), 269–283.
- [6] Maulida, L. (2018). Penerapan Data Mining dalam Mengelompokkan Kunjungan Wisatawan ke Objek Wisata Unggulan di Prov. DKI Jakarta dengan *K-Means*. *JISKA (Jurnal Informatika Sunan Kalijaga)*, 2(3), 167. <https://doi.org/10.14421/jiska.2018.23-06>.

-
- [7] Sadli, M., Fajriana, F., Fuadi, W., Ermatita, E., & Pahendra, I. (2018). Penerapan Model K-Nearest Neighbors Dalam Klasifikasi Kebutuhan Daya Listrik Untuk Masing-Masing Daerah Di Kota Lhokseumawe. *Jurnal ECOTIPE*, 5(2),11–18. <https://doi.org/10.33019/ecotipe.v5i2.646>.
- [8] Methods D, R. Wati, B. Sembiring, F. A. Mohammed, and K. Chairuang. (2020). Customer Segmentation Based on RFM Model Using. Vol. 11, no. 1, pp. 32–43, 2020.
- [9] Mustofa Z and I. S. Suasana. (2018). Algoritma Clustering K-Medoids Pada E-Government Bidang Information And Communication . *Jurnal Teknol dan Komun*. Vol. 9, pp. 1–10, 2018.
- [10] Damanik I. I. P, S. Solikhun, I. S. Saragih, I. Parlina, D. Suhendro, and A. Wanto. (2019). Algoritma K-Medoids untuk Mengelompokkan Desa yang Memiliki Fasilitas Sekolah di Indonesia. *Pros. Semin. Nas. Ris. Inf. Sci*. Vol. 1, no. September, p. 520, 2019, <https://doi.org/10.30645/senaris.v1i10.58>.
- [11] Sari, Y. R., Sudewa, A., Lestari, D. A., & Jaya, T. I. (2020). Penerapan Algoritma K-Means Untuk Clustering Data Kemiskinan Provinsi Banten Menggunakan Rapidminer. *CESS (Journal of Computer Engineering, System and Science)*. 5(2), 192. <https://doi.org/10.24114/cess.v5i2.18519>.
- [12] Sadewo, M. G., Windarto, A. P., & Wanto, A. (2018). Penerapan Algoritma Clustering Dalam Mengelompokkan Banyaknya Desa/Kelurahan Menurut Upaya Antisipasi/ Mitigasi Bencana Alam Menurut Provinsi Dengan K-Means. *KOMIK (Konferensi Nasional Teknologi Informasi Dan Komputer)*. 2(1). <https://doi.org/10.30865/komik.v2i1.943>.
- [13] Talakua, M. W., Leleury, Z. A., & Talluta, A. W. (2017). Acluster Analysis By Using K-Means Method for Grouping of District/City in Maluku Province Industrial Based on Indicators of Maluku Development Index in 2014. *Barekeng : Jurnal Ilmu Matematika Dan Terapan*. 11(2), 119–128. <https://doi.org/10.30598/barekengvol11iss2pp119-128>.
- [14] Aji, B. N. B., Nafi'iyah, N., & Sholihin, M. (2019). Implementasi Som Dalam Clustering Hasil Ikan Laut Kabupaten Pekalongan. *Jurnal Elektronika, Listrik Dan Teknologi Informasi Terapan*. 2, 1–7. <https://doi.org/10.37338/e.v2i1.114>.
- [15] Nishom, M. (2019). Perbandingan Akurasi Euclidean Distance, Minkowski Distance, dan Manhattan Distance pada Algoritma K-Means Clustering berbasis Chi-Square. *Jurnal Informatika: Jurnal Pengembangan IT*. 4(1), 20–24. <https://doi.org/10.30591/jpit.v4i1.1253>.
- [16] Abdullah, D., Susilo, S., Ahmar, A. S., Rusli, R., & Hidayat, R. (2021). The application of K-means clustering for province clustering in Indonesia of the risk of the COVID-19 pandemic based on COVID-19 data. *Quality and Quantity*, 0123456789. <https://doi.org/10.1007/s11135-021-01176-w>.
- [17] Wira, B., Budianto, A. E., & Wiguna, A. S. (2019). Implementasi Metode K-Medoids Clustering Untuk Mengetahui Pola Pemilihan Program Studi Mahasiswa Baru Tahun 2018 Di Universitas Kanjuruhan Malang. *RAINSTEK : Jurnal Terapan Sains & Teknologi*. 1(3), 53– 68. <https://doi.org/10.21067/jtst.v1i3.3046>.
- [18] Sindi, S., Ningse, W. R. O., Sihombing, I. A., Ilmi R.H.Zer, F., & Hartama, D. (2020). Analisis algoritma K-Medoids clustering dalam pengelompokan penyebaran Covid-19 di Indonesia. *Jti (Jurnal Teknologi Informasi)*. 4(1), 166–173.
- [19] Arbin, N., Suhaimi, N. S., Mokhtar, N. Z., & Othman, Z. (2016). Comparative analysis between k-means and k-medoids for statistical clustering. *Proceedings - AIMS 2015, 3rd International Conference on Artificial Intelligence, Modelling and Simulation*. 117– 121. <https://doi.org/10.1109/AIMS.2015.82>.
- [20] A. K. Singh, S. Mittal, P. Malhotra, and Y. V. Srivastava. (2020). Clustering Evaluation by Davies Bouldin Index(DBI) in Cereal data using K Means. *Proc. 4th Int. Conf. Comput. Methodol. Commun (ICCMC)* no. Iccmc, pp. 306–310, <https://doi.org/10.1109/ICCMC48092.2020.57>.
-