

Penerapan Fuzzy C-Means Pada Klasterisasi Penerima Bantuan Pangan Non Tunai

Sola Huddin*, Elin Haerani, Jasril, Lola Oktavia

Sains dan Teknologi, Teknik Informatika, Uin Sultan Syarif Kasim Riau, Pekanbaru, Indonesia

Email: ¹*111950115224@students.uin-suska.ac.id, ²elin.haerani@uin-suska.ac.id, ³jasril@uin-suska.ac.id,

⁴lola.oktavia@uin-suska.ac.id

Email Penulis Korespondensi: 111950115224@students.uin-suska.ac.id

Abstrak—Program bantuan sosial yang rutin diberikan oleh pemerintah kepada Keluarga Penerima Manfaat (KPM) untuk mengatasi masalah kemiskinan di Indonesia pada saat ini salah satunya adalah Bantuan Pangan Non Tunai (BPNT). Dinas Sosial kota Pekanbaru sendiri dalam penyaluran BPNT masih mengalami kendala, seperti pemberian bantuan yang kurang tepat sasaran dikarenakan belum adanya sistem yang mampu untuk menentukan penerima bantuan secara tepat. Penelitian ini menerapkan metode *Fuzzy C-Means Clustering* untuk menganalisis data KPM menggunakan *tools* MATLAB. Algoritma ini memungkinkan adanya tumpang tindih antara kelompok data dan mengelompokkan KPM berdasarkan pola karakteristiknya. Algoritma ini memperhitungkan tingkat keanggotaan setiap data dalam setiap kelompok, sehingga memberikan hasil yang lebih fleksibel dan tidak mengkategorikan data secara kaku. Hasil penerapan metode FCM *Clustering* dalam penelitian ini membentuk dua klaster, yang mana klaster pertama berisikan 331 data sedangkan pada klaster kedua sebanyak 351 data. Pengujian hasil klasterisasi FCM yang dilakukan menggunakan metode *Silhouette Coefficient* menghasilkan nilai rata-rata koefisiennya sebesar 0.426653079. Berdasarkan nilai hasil pengujian yang telah dilakukan, algoritma FCM dinilai mampu dalam membentuk klaster pada data BPNT.

Kata Kunci: BPNT; Cluster; Fuzzy C-Means; Silhouette Coefficient;

Abstract—One of the social assistance programs routinely provided by the government to Beneficiary Families (KPM) to overcome poverty problems in Indonesia at this time is Non-Cash Food Assistance (BPNT). The Pekanbaru City Social Service itself in distributing BPNT still experiences obstacles, such as the provision of assistance that is less targeted due to the absence of a system that is able to determine the recipient of aid appropriately. This research applies the Fuzzy C-Means Clustering method to analyze KPM data using MATLAB tools. This algorithm allows overlap between data groups and classifies KPM based on their characteristic patterns. This algorithm takes into account the membership level of each data in each group, thus providing more flexible results and not categorizing data rigidly. The results of the application of the FCM Clustering method in this study form two clusters, where the first cluster contains 331 data while in the second cluster there are 351 data. Testing the results of FCM clustering conducted using the Silhouette Coefficient method produces an average coefficient value of 0.426653079. Based on the value of the test results that have been carried out, the FCM algorithm is considered capable of forming clusters on BPNT data.

Keywords: BPNT; Cluster; Fuzzy C-Means; Silhouette Coefficient;

1. PENDAHULUAN

Kemiskinan merupakan keadaan yang ditandai oleh kekurangan materi yang signifikan pada individu atau sekelompok orang tertentu, yang secara jelas mengekspos perbedaan mereka dengan standar hidup umum yang ada di komunitas tersebut [1]. Pasal 1(1) dari Keppres RI No. 63/2017 menggambarkan konsep sorongan penghidupan sebagai bentuk dukungan yang mencakup pemberian dana, materi, atau pelayanan kepada perorangan atau kelompok masyarakat yang menghadapi keadaan kemiskinan, ketidakmampuan, atau risiko-risiko sosial yang mengancam keberlangsungan hidup mereka [2]. Sebagai bagian dari inisiatif untuk mengatasi masalah kemiskinan dan memperbarui efektivitas Program Subsidi Rastra yang telah diterapkan di Indonesia, pemerintah telah mengimplementasikan Program Bantuan Pangan Non Tunai (BPNT). Program ini merupakan langkah strategis yang bertujuan untuk meningkatkan pendekatan dalam penyediaan bantuan pangan kepada masyarakat dengan mengadopsi sistem pembayaran non tunai, yang bermaksud meningkatkan efisiensi dan akurasi sasaran program, sekaligus mendorong inklusi keuangan di bawah kepemimpinan Presiden Republik Indonesia [3].

BPNT telah diperkenalkan dan dilaksanakan di berbagai daerah di Indonesia, termasuk Kota Pekanbaru yang menjadi salah satu wilayah yang melibatkan diri dalam pelaksanaan program tersebut. Dengan menerapkan program ini, diharapkan bahwa warga di Kota Pekanbaru dapat memperoleh manfaat langsung dalam bentuk bantuan pangan yang disalurkan secara non tunai, sehingga meningkatkan aksesibilitas dan keberlanjutan bantuan tersebut. Menurut hasil wawancara dengan petugas dinas sosial yang mengelola data DTKS kota Pekanbaru terbukti berhasil, namun masih terdapat beberapa masalah seperti bantuan yang tidak dibagikan secara merata karena tidak mengenal kaya dan miskin, sehingga bantuan yang diberikan menjadi tidak tepat sasaran [4]. Dalam upaya mengatasi masalah ini peneliti membentuk klaster pada data BPNT dengan memanfaatkan metode *clustering* yang menggunakan algoritma Fuzzy C-Means (FCM) dengan *tools* MATLAB, metode ini dapat membantu dalam membentuk klaster data penerima bantuan pada Dinsos Kota Pekanbaru.

Penerapan algoritma FCM pada penelitian ini menggunakan perangkat lunak MATLAB, algoritma FCM memanfaatkan fungsi derajat keanggotaan untuk mengukur sejauh mana titik data berada dalam klaster yang ditentukan, sehingga memungkinkan pemisahan yang lebih akurat dan menghindari kesalahan dalam pengelompokan data [5]. Dalam algoritma FCM, perlu untuk mengetahui jumlah klaster yang akan dibentuk sebelumnya, maka algoritma ini digolongkan sebagai algoritma pengelompokan yang terawasi [6]. Salah satu konsep dasar dalam algoritma FCM adalah menentukan

posisi pusat klaster, yang menunjukkan lokasi setiap kelompok. Pada tahap awal, posisi pusat klaster belum sepenuhnya akurat. Oleh karena itu, melalui serangkaian iterasi, algoritma ini berusaha memperbaiki posisi pusat klaster dan memperbarui derajat keanggotaan setiap titik data. Proses ini melibatkan penyesuaian posisi pusat klaster dan penyesuaian derajat keanggotaan untuk mengoptimalkan fungsi objektif yang mengukur jarak antara titik data dan pusat klaster yang diwakili oleh bobot derajat keanggotaan [7]. MATLAB memberikan kemampuan komputasi yang kuat dalam pemrosesan data dan analisis statistik, memungkinkan implementasi yang efisien dari metode FCM. Dengan menggunakan MATLAB, akan memperoleh hasil klasterisasi yang optimal dan akurat, sehingga memastikan setiap titik data tergabung dalam kelompok yang sesuai dengan karakteristiknya.

Pada penelitian dengan judul Analisis Clustering Untuk Recredensialing Fasilitas Kesehatan Menggunakan Metode Fuzzy C-Means, yang berfokus pada penerapan metode FCM *clustering* dalam mengelompokkan data profil penyedia layanan faskes, dengan tujuan untuk menghasilkan klaster yang mampu berkolaborasi secara efektif dengan pihak BPJS Kesehatan. Dalam implementasinya, metode FCM menghasilkan dua klaster, di mana klaster pertama terdiri dari 479 data, sementara klaster kedua terdiri dari 580 data [8]. Selain dari penelitian ini, terdapat beberapa penelitian lain yang telah dilakukan dengan fokus pada FCM *clustering*. Penelitian-penelitian tersebut mencakup berbagai aspek dan aplikasi dari FCM *clustering* dalam berbagai bidang seperti pengenalan pola, analisis data, pengolahan citra, dan bioinformatika. Beberapa penelitian yang juga membahas algoritma FCM diantaranya adalah Implementasi Fuzzy C-Means pada Sistem Pendukung Keputusan BPNT (Bantuan Pangan Non-Tunai) Kementerian Sosial Indonesia oleh Aji Setiawan (2019) [9], Fuzzy Clustering dan Fuzzy C-Means Partisi Analisis Cluster dan Studi Validasi Pada Subset Dataset CiteScore oleh K. Varada Rajkumar (2019) [10], Analisis Cluster Menggunakan Algoritma K-Means dan Fuzzy C-Means Clustering untuk Pengelompokan Kemampuan Mahasiswa dalam Proses Pembelajaran Daring oleh Indah Purnama Sari (2021) [11], Algoritma Fuzzy C-Means *Clustering* Untuk Pengelompokan Pusat Pelayanan Kesehatan Pada Penyakit Diare oleh Ahmad Chusyairi (2021) [12].

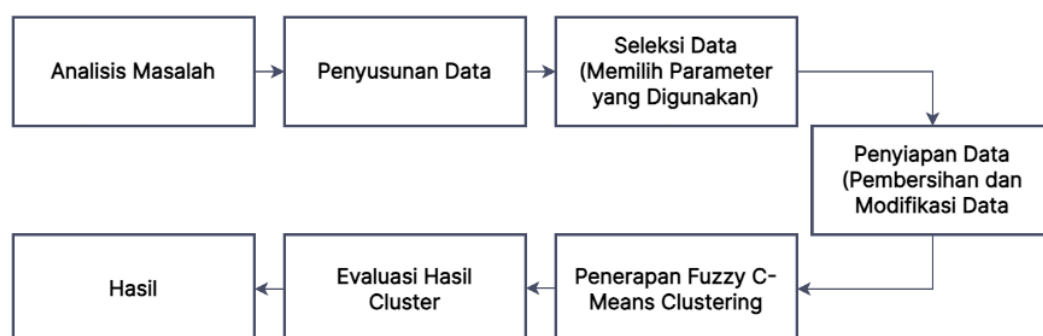
Dari temuan-temuan yang telah ada sebelumnya, dapat disimpulkan bahwa algoritma Fuzzy C-Means (FCM) memiliki potensi yang signifikan sebagai pendekatan yang efektif dalam melaksanakan proses klasterisasi terhadap data Bantuan Pangan Non-Tunai (BPNT). Dalam konteks penelitian ini, studi kasus yang diambil adalah dinas sosial di kota Pekanbaru. FCM digunakan sebagai alat yang dapat membantu dalam mengelompokkan data BPNT untuk memahami pola dan karakteristik yang ada dalam program bantuan sosial tersebut. Penelitian ini menunjukkan bahwa FCM dapat menjadi pendekatan yang efisien dan efektif dalam klasterisasi data BPNT, sehingga memberikan wawasan yang berharga bagi pemerintah kota Pekanbaru dalam meningkatkan pengelolaan dan manajemen program bantuan pangan yang lebih baik [13], [14]. Kemampuan FCM dalam mengelompokkan data secara adaptif dan memperhitungkan derajat keanggotaan masing-masing titik data memungkinkannya untuk menghasilkan klaster yang lebih akurat dan representatif. Dengan begitu, kontribusi penelitian ini memperkuat pemahaman tentang efektivitas FCM dalam konteks klasterisasi data BPNT dan mengarahkan pada potensi pengembangan lebih lanjut dalam bidang ini.

Penelitian ini bertujuan untuk memberikan kontribusi yang signifikan dalam literatur terkait, terutama sebagai referensi yang komprehensif dan pembandingan bagi penelitian-penelitian serupa yang menerapkan algoritma klasterisasi yang berbeda dalam analisis data serupa. Dengan menggunakan metode Fuzzy C-Means (FCM) sebagai algoritma klasterisasi yang dipilih, penelitian ini membuka peluang yang menarik untuk secara mendalam mengeksplorasi, mengidentifikasi, dan memahami karakteristik serta pola yang terkait dengan implementasi program bantuan sosial BPNT di dalam konteks dinas sosial kota Pekanbaru. Pembahasan dalam penelitian ini nantinya dapat dikembangkan untuk pembuatan sistem yang dapat menentukan penerima BPNT seperti yang dibahas pada penelitian tentang Implementasi Fuzzy C-Means Program Bantuan Langsung Tunai Pada Dinas Sosial Kabupaten Deli Serdang Distribusi Kecamatan Pancur Batu oleh Nia Persada Rita Br Sinuhaji (2021) [15].

2. METODOLOGI PENELITIAN

2.1 Tahapan Penelitian

Langkah-langkah yang dilakukan untuk mengidentifikasi, memproses, dan menghasilkan pengetahuan dalam penelitian ini dilakukan melalui berbagai tahapan. Tahapan-tahapan tersebut dapat dilihat pada gambar 1.



Gambar 1. Tahapan Penelitian

2.1.1 Penyusunan Data

Langkah selanjutnya adalah penyusunan data yang dimana pada tahapan ini data diperoleh dari penelitian terdahulu oleh Firza Syahputra (2022) dengan judul Sistem Pendukung Keputusan Bantuan Pangan Non Tunai Menggunakan Metode Fuzzy-Analytical Hierarchy Process Dan Topsis, data yang digunakan merupakan data dinas sosial kota Pekanbaru tahun 2020-2021 dengan total data 732 dan 42 parameter.

2.1.2 Seleksi Data

Pada tahapan *selection* data, atribut yang memiliki nilai 0 dan *null* (kosong) akan dihapus karena tidak memiliki pengaruh yang signifikan terhadap data. Parameter yang digunakan diambil berdasarkan kriteria penerima bantuan atau yang tergolong masyarakat miskin menurut standar Badan Pusat Statistik (BPS). Setelah melakukan tahapan *selection* pada data, jumlah atribut yang digunakan hanya 24, ini berarti ada sebanyak 18 atribut yang dihapus karena dirasa tidak memiliki pengaruh yang signifikan terhadap proses klasterisasi dan tidak sesuai dengan kriteria penerima bantuan sosial yang ditentukan oleh BPS.

2.1.3 Pre-Processing

Tahapan *pre-processing* ini berupaya untuk melakukan *cleaning* dan transformasi, agar data yang digunakan menjadi bersih atau terhindar dari nilai 0 dan *null* (kosong). Proses ini juga bertujuan untuk mengubah data yang ada menjadi bentuk numerik, hasil dari tahapan ini ditampilkan pada tabel 1.

Tabel 1. Tahapan Pre-Processing Pada Data

Atribut	Data Awal	Hasil Transformasi
Status Tinggal	Dinas	5
	Milik Sendiri	4
	Bebas Sewa	3
	Sewa	2
	Lainnya	1
Lantai Terluas	Marmer/Granit	9
	Marmer/Granit Lainnya	8
	Keramik	7
	Batu Merah	6
	Kayu/Papan Kualitas Tinggi	5
	Kayu/Papan Kualitas Rendah	4
	Parket/Vinil/Permadani	3
	Lainnya	2
	Tanah	1
Dinding Terluas	Tembok	5
	Plaster	4
	Kayu	3
	Batang Kayu	2
	Lainnya	1
Jenis Air Minum	Air Kemasan Bermerk	10
	Air Kemasan Bermerk Isi Ulang	9
	Air Isi Ulang	8
	Leding Eceran	7
	Leding Meteran	6
	Sumur Bor Pompa	5
	Sumur Terlindungi	4
	Sumur Tidak Terlindungi	3
	Mata Air Terlindungi	2
	Mata Air Tidak Terlindungi	1
...
Rumah Lainnya	Ya	2
	Tidak	1

2.2 Data Mining

Data mining juga disebut sebagai proses menemukan hubungan atau korelasi antara ribuan field dengan jumlah data yang besar. Ini adalah teknik yang memungkinkan untuk memprediksi objek yang menarik dengan terlebih dahulu mengetahui

apakah objek tertentu dapat ditemukan melalui jumlah data yang besar [16]. Dalam konteks penelitian data mining bertujuan untuk mengungkapkan pola dan informasi yang berharga dari kumpulan data yang besar dan kompleks [17].

2.3 Fuzzy C-Means Clustering

Algoritma Clustering Fuzzy C-Means (FCM) adalah algoritma yang sering digunakan dalam pengenalan pola dan analisis data. Keunggulan utamanya terletak pada kemampuannya mengklasifikasikan data dengan tingkat keanggotaan yang tidak eksklusif. Dalam FCM, nilai keanggotaan berada dalam rentang 0 hingga 1, mencerminkan derajat keanggotaan setiap objek terhadap setiap kluster. Ini memungkinkan pengelompokan data yang fleksibel dan memungkinkan analisis yang lebih rinci dan mendalam terhadap pola dan hubungan antarobjek dalam data [18]. Pendekatan *soft clustering*, yang membedakan *fuzzy-c-means* dari *hard clustering*, memberikan skor kemungkinan setiap titik data untuk menjadi bagian dari kluster [19]. Adapun tahapan yang dilakukan dalam menjalankan algoritma *fuzzy c-means* pada penelitian ini antara lain [20].

a. Inputkan data

Untuk mengelompokkan data dengan menggunakan algoritma clustering, data tersebut akan diorganisir dalam format matriks $n \times m$, di mana n menyatakan jumlah sampel data yang ada dan m menyatakan jumlah parameter yang dimiliki oleh sampel data. Dalam matriks tersebut, setiap elemen X_{ij} mengindikasikan nilai atribut ke- j dari sampel data ke- i , dengan i yang bervariasi dari 1 hingga n dan j yang bervariasi dari 1 hingga m . Melalui representasi matriks ini, data dapat disusun secara terstruktur, memungkinkan analisis dan pemrosesan lebih lanjut untuk mengidentifikasi pola dan hubungan yang ada di antara atribut-atribut tersebut. Dengan mengorganisir data dalam format matriks, peneliti dapat menggunakan algoritma clustering dengan lebih efisien untuk mengelompokkan dan menggali wawasan yang berharga dari kumpulan data yang kompleks dan multidimensional.

b. Berikan Batasan

1. Jumlah *cluster* / c = 2
2. Pangkat / w = 2
3. Maksimum iterasi / MaxIt = 100
4. Error terkecil / ξ = 0,001
5. Fungsi objektif awal / P_0 = 0
6. Iterasi awal / t = 1

c. Inisialisasi nilai random

Untuk mendapatkan matriks partisi awal U , bilangan acak μ_{ik} (dengan i bervariasi dari 1 hingga n dan k bervariasi dari 1 hingga c) akan dihasilkan dan digunakan sebagai elemen-elemen dalam matriks tersebut. Dalam matriks partisi awal U , setiap elemen U_{ik} mencerminkan tingkat keanggotaan atau probabilitas bahwa sampel data ke- i termasuk dalam kluster ke- k . Nilai kolom setiap baris dalam matriks tersebut ditetapkan sebagai 1 (satu), menunjukkan bahwa setiap sampel data memiliki tingkat keanggotaan maksimum dalam satu kluster pada tahap awal. Melalui generasi bilangan acak μ_{ik} dan penugasan nilai kolom yang konsisten, matriks partisi awal U dapat disusun untuk memulai proses klasterisasi dengan FCM. Dengan demikian, langkah ini memberikan titik awal yang acak namun konsisten dalam menginisiasi perhitungan derajat keanggotaan setiap sampel data dalam setiap kluster.

$$\sum_{i=1}^c \mu_{ci} = 1 \quad (1)$$

d. Menghitung pusat *cluster*

$$P_t = \frac{\sum_{i=1}^n ((\mu_{ci})^w * X_{ci})}{\sum_{i=1}^n (\mu_{ci})^w} \quad (2)$$

e. Menghitung jumlah fungsi objektif

$$P_t \sum_{i=1}^c \sum_{j=1}^n ([\sum_{i=1}^c (x_{ij} - V_{kj})]^w (\mu_{ik})^w) \quad (3)$$

f. Menghitung matriks keanggotaan

$$P_t \frac{[\sum_{j=1}^m (x_{ij} - v_{kj})^2]^{\frac{-1}{w-1}}}{\sum_{i=1}^c [\sum_{j=1}^m (x_{ij} - v_{kj})^2]^{\frac{-1}{w-1}}} \quad (4)$$

g. Mengevaluasi posisi berhenti

1. Jika: $(|P_t - P_{t-1}| < \xi)$ atau $(t > \text{MaxIter})$ maka berhenti;
2. Jika tidak: $t = t + 1$, ulangi langkah ke-d (menghitung V_{kj}).

2.4 Evaluasi Cluster

Pengujian terhadap hasil kluster dilakukan dengan menggunakan metode *Silhouette Coefficient*, metode evaluasi ini digunakan untuk mengukur kualitas klasterisasi dalam analisis data. Metode ini menggambarkan sejauh mana kesesuaian setiap titik data dengan klasternya sendiri dibandingkan dengan kluster lainnya, dengan memberikan nilai numerik dalam rentang -1 hingga 1. Perhitungan *Silhouette Coefficient* mempertimbangkan jarak antara titik data dengan titik-titik dalam

klaster yang sama (jarak intra-klaster) dan jarak antara titik data dengan titik-titik dalam klaster lain (jarak inter-klaster). Nilai *Silhouette Coefficient* mendekati 1 menunjukkan bahwa titik data terklaster dengan baik dan secara tepat berada dalam klasternya. Ketika nilai mendekati -1, itu mengindikasikan adanya kemungkinan bahwa titik data ditempatkan di klaster yang tidak sesuai, sedangkan nilai yang mendekati 0 menunjukkan bahwa titik data berada pada daerah yang dekat dengan batas antara klaster.

3. HASIL DAN PEMBAHASAN

3.1 Tahapan Normalisasi Data

Ketika melangsungkan analisis terhadap data, peneliti menemukan bahwa terdapat perbedaan cakupan atau rentang nilai antara beberapa atribut yang diamati. Faktor ini menimbulkan kekhawatiran karena atribut dengan nilai yang tinggi memiliki potensi pengaruh yang lebih signifikan dari pada atribut dengan nilai yang lebih rendah, sehingga dapat mengarah pada distorsi atau ketidak seimbangan dalam analisis data. Untuk mengatasi masalah ini, peneliti mengambil langkah-langkah dalam melakukan normalisasi atribut, dengan tujuan untuk mengubah atribut-atribut tersebut sehingga memiliki rentang nilai yang seragam atau cakupan yang sama. Melalui normalisasi, atribut-atribut dengan rentang yang berbeda dapat diubah menjadi skala yang relatif sehingga dapat dibandingkan dan dianalisis dengan lebih akurat. Hasil dari normalisasi ini kemudian disajikan dalam Tabel 2, yang menampilkan data yang telah melalui proses normalisasi. Dalam tabel tersebut, atribut-atribut telah disesuaikan secara proporsional sehingga dapat digunakan untuk analisis selanjutnya dengan mempertimbangkan pengaruh masing-masing atribut secara seimbang.

Tabel 2. Data Setelah Melalui Tahapan Normalisasi

Status Tinggal	Dimensi Lantai	Lantai Terluas	Dinding Terluas	...	Rumah Lainnya
1	20	2	5	...	1
2	2	4	3	...	1
2	9	2	4	...	1
4	4	6	5	...	1
1	20	9	4	...	1
2	36	4	3	...	1
2	24	4	3	...	1
2	12	7	4	...	1
...
2	36	5	3	...	1
2	40	7	3	...	1
2	4	8	3	...	1
2	36	1	3	...	1

Pada Tabel 2 diatas menampilkan data yang telah melewati tahapan normalisasi data agar cakupannya sesuai dan dapat mendapatkan hasil yang diinginkan. Tahapan selanjutnya data disimpan dalam bentuk file.dat dengan menghilangkan nama atribut agar tidak mengganggu proses perhitungan, data yang disimpan ini nantinya akan dijalankan dengan MATLAB untuk kemudian dilakukan klasterisasi FCM.

3.2 Fuzzy C-Means Clustering Menggunakan Matlab

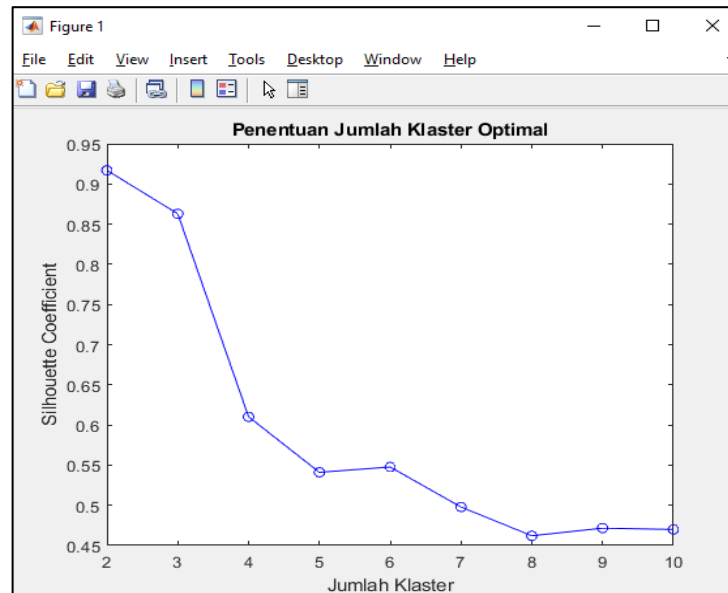
Tahap pertama dalam proses klasterisasi dengan menggunakan algoritma FCM adalah menentukan jumlah klaster optimal yang memberikan hasil terbaik dalam analisis data. Metode *Max Average Silhouette Coefficient* digunakan sebagai kriteria untuk menentukan jumlah klaster optimal. Metode ini bertujuan untuk mengevaluasi kualitas dan kompaknya klaster yang terbentuk berdasarkan hubungan antara jarak antar-sampel dalam satu klaster dengan jarak antar-sampel antarklaster. Dalam gambar yang disajikan, dapat dilihat hasil dari pencarian jumlah klaster optimal terbaik yang ditunjukkan oleh nilai Optimal K. Peneliti telah membatasi jumlah maksimal klaster yang akan dieksplorasi hingga 10, dan hasilnya digambarkan dalam gambar tersebut. Melalui proses ini, peneliti dapat memperoleh informasi yang penting untuk menentukan jumlah klaster yang optimal dalam analisis klasterisasi data, berdasarkan kriteria siluet yang diadopsi.

```
Jumlah Cluster: 10, Silhouette Coefficient: 1.0000
Optimal K: 2
```

Gambar 2. Hasil Pencarian Jumlah Klaster Optimal

Berdasarkan hasil pencarian jumlah klaster optimal yang telah dilakukan, hasilnya dapat digambarkan dalam grafik Nilai Silhouette. Grafik ini memberikan visualisasi yang jelas mengenai hubungan antara jumlah klaster yang dieksplorasi dan nilai Silhouette yang terkait. Dalam analisis ini, dapat dilihat bahwa grafik Nilai Silhouette menunjukkan bahwa jumlah klaster optimal yang ditemukan adalah dua. Rincian lebih lanjut mengenai informasi ini dapat ditemukan dalam Gambar 3 yang disajikan, di mana grafik tersebut memberikan gambaran visual yang jelas tentang bagaimana nilai Silhouette berubah seiring dengan peningkatan jumlah klaster yang dieksplorasi. Dengan memperhatikan grafik ini, peneliti dapat

memperoleh pemahaman yang lebih baik mengenai jumlah kluster yang memberikan hasil klasterisasi yang optimal berdasarkan metode *Max Average Silhouette Coefficient* yang digunakan.



Gambar 3. Grafik Pencarian Jumlah Kluster Optimal

Pada gambar 3 yang disajikan, terdapat grafik yang menampilkan proses pencarian jumlah kluster optimal menggunakan metode *Max Average Silhouette Coefficient*. Dalam penentuan jumlah kluster, metode ini mempertimbangkan nilai *Silhouette Coefficient* tertinggi untuk menentukan jumlah kluster yang optimal, dan hasilnya menunjukkan bahwa jumlah kluster optimal adalah 2. Setelah berhasil mendapatkan jumlah kluster optimum, langkah selanjutnya dalam proses klasterisasi adalah menghitung nilai fungsi objektif dalam setiap iterasi menggunakan aplikasi MATLAB, dengan tujuan untuk mencapai konvergensi dalam hasil klasterisasi. Gambar 4 menampilkan hasil dari iterasi yang telah dilakukan, di mana dapat dilihat perubahan nilai fungsi objektif dari iterasi ke iterasi dalam proses klasterisasi. Dengan mempelajari gambar ini, peneliti dapat menganalisis konvergensi hasil klasterisasi dan memahami perubahan yang terjadi seiring dengan proses iterasi yang dilakukan.

```

Iteration count = 11, obj. fcn = 3652.660552
Iteration count = 12, obj. fcn = 3645.839884
Iteration count = 13, obj. fcn = 3636.681866
Iteration count = 14, obj. fcn = 3626.103299
Iteration count = 15, obj. fcn = 3616.065104
Iteration count = 16, obj. fcn = 3608.469739
Iteration count = 17, obj. fcn = 3603.880613
Iteration count = 18, obj. fcn = 3601.586935
Iteration count = 19, obj. fcn = 3600.581839
Iteration count = 20, obj. fcn = 3600.169374
Iteration count = 21, obj. fcn = 3600.000578
Iteration count = 22, obj. fcn = 3599.928057
Iteration count = 23, obj. fcn = 3599.894328
Iteration count = 24, obj. fcn = 3599.877271
Iteration count = 25, obj. fcn = 3599.868033
Iteration count = 26, obj. fcn = 3599.862789
Iteration count = 27, obj. fcn = 3599.859726
Iteration count = 28, obj. fcn = 3599.857906
Iteration count = 29, obj. fcn = 3599.856816
Iteration count = 30, obj. fcn = 3599.856159

```

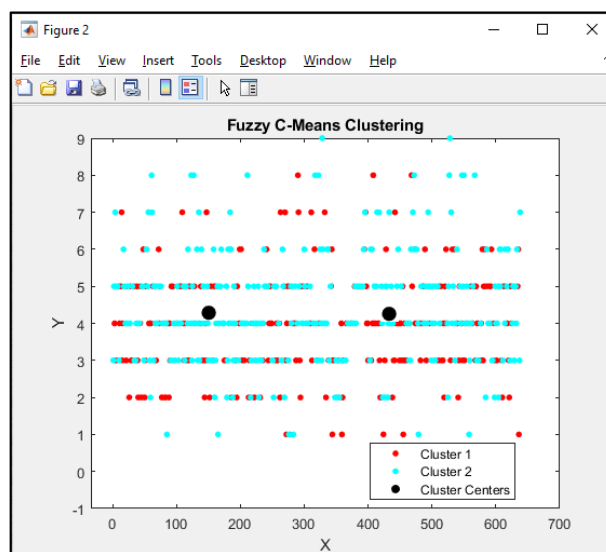
Gambar 4. Perhitungan Setiap Iterasi

Setelah nilai fungsi objektif tidak mengalami perubahan yang signifikan dari iterasi sebelumnya, maka nilai dinyatakan telah tercapai dan proses perhitungan dihentikan. Pada tabel diatas perhitungan yang dilakukan berhenti pada iterasi ke-30 dengan hasil fungsi objektif 3599.857041. Selanjutnya dilakukan pembentukan kluster berdasarkan hasil iterasi yang didapatkan, sehingga didapatkan nilai centroid yang nantinya digunakan sebagai pusat kluster. Tabel 3 menyajikan informasi yang menggambarkan hal tersebut dengan lebih jelas.

Tabel 3. Matriks Cluster Center

Cluster 1	Cluster 2
2.3889	2.5717
1.2506	1.2732
6.0314	5.8999
4.1139	3.8716
7.3779	5.1767
2.9766	2.9734
2.5249	2.4270
3.9074	3.9229
3.8181	3.8094
1.7564	1.7381
...	...
1.0021	1.0006
1.0277	1.0387
1.0133	1.0085

Dalam Tabel 3 terlihat beberapa hasil pusat klaster yang mencerminkan nilai-nilai atribut pada data. Pusat klaster ini akan menjadi acuan dalam menentukan posisi klaster untuk setiap data. Informasi lebih lanjut mengenai penentuan letak klaster data dapat ditemukan dalam Gambar 5 yang menampilkan visualisasi grafis dari hasil klasterisasi.

**Gambar 5.** Visualiasi Hasil Klasterisasi

Tampilan grafik dalam Gambar 5 merupakan visualisasi dari hasil klasterisasi menggunakan algoritma FCM, di mana terlihat pembagian klaster berdasarkan titik-titik centroid. Pada grafik tersebut, titik-titik yang diberi warna hitam mewakili pusat klaster 1 dan 2. Sementara itu, lingkaran-lingkaran yang terbentuk melambangkan kumpulan data yang termasuk dalam masing-masing klaster. Untuk memberikan representasi yang jelas, klaster satu ditandai dengan warna *candy apple*, untuk klaster dua ditunjukkan dengan warna *aqua*. Dalam upaya mendapatkan gambaran yang lebih detail mengenai hasil klasterisasi, informasi lebih lanjut dapat ditemukan pada Tabel 4. Tabel tersebut memberikan rincian mengenai atribut-atribut yang terdapat dalam setiap klaster, serta jumlah sampel data yang termasuk dalam masing-masing klaster. Dengan melihat grafik dan tabel ini, peneliti dapat memperoleh pemahaman yang komprehensif mengenai hasil klasterisasi yang telah dilakukan menggunakan algoritma FCM.

Tabel 4. Hasil Cluster

Data Ke-	Status Tinggal	Dimensi Lantai	Lantai Terluas	Dinding Terluas	...	Cluster
1	1	20	2	5	...	2
2	2	2	4	3	...	2
3	2	9	2	4	...	1
4	4	4	6	5	...	1
5	1	20	9	4	...	2
6	2	36	4	3	...	2
7	2	24	4	3	...	1
8	2	12	7	4	...	2
9	4	6	5	4	...	2

...
680	2	40	7	3	...	2
681	2	4	8	3	...	1
682	2	36	1	3	...	1

Dalam Tabel 4 terlihat hasil dari pengelompokan data BPNT di Dinsos kota Pekanbaru yang menerapkan proses FCM. Total 682 data yang tersedia, sebanyak 331 data termasuk ke dalam klaster 1, sementara 351 data lainnya masuk ke dalam klaster 2. Klaster 1 memiliki ciri khas yang menunjukkan tingkat ekonomi yang relatif lebih rendah jika dibandingkan dengan klaster 2, hal ini terlihat melalui nilai atribut yang terdapat pada data-data yang termasuk dalam klaster 1 yang mencerminkan kondisi sosioekonomi yang lebih rendah. Di sisi lain, klaster 2 memiliki nilai atribut yang cenderung lebih tinggi, menandakan tingkat ekonomi yang lebih baik. Berdasarkan perbedaan karakteristik ini, dapat disimpulkan bahwa klaster 1 memiliki prioritas yang lebih tinggi dalam menerima bantuan, sementara klaster 2 memiliki prioritas yang lebih rendah karena nilai atributnya yang cenderung lebih tinggi.

3.3 Pengujian Hasil Cluster

Pada penelitian ini pengujian terhadap hasil klasterisasi data yang menerapkan Algoritma FCM *Clustering* menggunakan metode evaluasi *Silhouette Coefficient*, yang mengukur sejauh mana data tersebut terkelompokkan dengan baik dalam klasternya sendiri dibandingkan dengan klaster lain, dengan rentang nilai antara -1 hingga 1. Hasil pengujian *Silhouette Coefficient* terhadap hasil klasterisasi 682 data mendapatkan rata-rata nilai koefisien sebesar 0.426653079, untuk pengujian tiap data dapat ditemukan dalam Tabel 5.

Tabel 5. Hasil Pengujian Cluster Menggunakan Silhouette Coefficient

Data Ke-	1-15	16-30	31-45	46-60	61-75	76-90	...	653-667	668-682
Hasil Pengujian	0.3432	0.3628	0.4432	0.3325	0.3314	0.4175	...	0.5099	0.4487
	0.4546	0.377	0.5084	0.5264	0.5355	0.508	...	0.5072	0.5382
	0.2334	0.5284	0.5265	0.4703	0.5201	0.4968	...	0.4414	0.5589
	0.476	0.522	0.4141	0.4451	0.4462	0.4165	...	0.4129	0.3928
	0.3891	0.4407	0.5113	0.4136	0.5506	0.525	...	0.5288	0.4346
	0.4572	0.4166	0.3154	0.345	0.5128	0.4676	...	0.3584	0.4099
	0.3559	0.5664	0.5388	0.4138	0.1846	0.5055	...	0.3969	0.5377
	0.5641	0.3264	0.374	0.4342	0.4427	0.2387	...	0.5094	0.4493
	0.4962	0.5191	0.3565	0.4389	0.3892	0.4621	...	0.3708	0.3659
	0.5442	0.3774	0.5203	0.478	0.5012	0.4304	...	0.524	0.6202
	0.5275	0.3821	0.5379	0.3398	0.262	0.4706	...	0.4385	0.3738
	0.3759	0.506	0.5246	0.4675	0.4757	0.4906	...	0.4603	0.524
	0.5217	0.5232	0.5136	0.5651	0.4285	0.4844	...	0.3502	0.5332
	0.5058	0.4858	0.469	0.4162	0.4838	0.3358	...	0.3408	0.3708
	0.3327	0.501	0.4543	0.3545	0.4898	0.4206	...	0.4258	0.1783

4. KESIMPULAN

Melalui penelitian yang dilakukan dalam rangka klasterisasi data Bantuan Pangan Non Tunai pada Dinas Sosial kota Pekanbaru menggunakan aplikasi MATLAB, dapat disimpulkan bahwa algoritma Fuzzy C-Means mampu dalam membentuk klaster pada data BPNT. Didapatkan jumlah cluster optimal untuk mengolah data BPNT adalah 2 klaster dengan menggunakan metode *Max Average Silhouette Coefficient*, sebanyak 331 data masuk kedalam klaster pertama dan 351 lainnya berada pada klaster kedua. Pengujian hasil klaster dilakukan dengan metode *Silhouette Coefficient* yang mendapatkan nilai yang cukup tinggi dengan rata-rata koefisien sebesar 0.426653079. Dari hasil analisis klasterisasi dapat disimpulkan bahwa, klaster pertama menunjukkan karakteristik yang menandakan kondisi ekonomi yang relatif lebih rendah jika dibandingkan dengan klaster kedua. Dengan demikian, hasil klasterisasi ini memberikan gambaran mengenai perbedaan karakteristik ekonomi antara kedua klaster yang diamati. Peneliti menyimpulkan klaster pertama memiliki prioritas lebih tinggi untuk menerima bantuan sosial dibandingkan dengan klaster kedua. Penelitian ini memiliki potensi untuk menjadi acuan bagi penelitian selanjutnya yang berfokus pada pengembangan dan peningkatan algoritma FCM. Selain itu, hasil penelitian ini juga dapat diimplementasikan dalam bentuk sistem yang dapat secara langsung dapat mengidentifikasi dan menentukan penerima bantuan sosial yang memenuhi syarat dan berhak menerima bantuan. Pengembangan juga dapat dilakukan dengan melakukan perbandingan algoritma FCM dengan algoritma clustering lainnya untuk mendapatkan hasil atau metode yang terbaik dalam klasterisasi data.

REFERENCES

- [1] D. M. Hasimi, "Analisis Program Bantuan Pangan Non Tunai (Bpnt) Guna Meningkatkan Kesejahteraan Masyarakat Dalam Perspektif Ekonomi Islam," *REVENUE: Jurnal Manajemen Bisnis Islam*, vol. 1, no. 01, hlm. 61–72, Jan 2020, doi: 10.24042/revenue.v1i01.5762.

- [2] M. Usna, T. Maemunaty, dan Widiastuti, "Implementation Of Non-Cash Food Assistance Program (Bpnt) Pekanbaru City Social Service In Tackling Poverty In The Maharatu Sub-District Of Peaceful Marpoyan Sub-District," JOM FKIP VOLUME, vol. 6, no. 1, Jun 2019.
- [3] H. Gultom, P. Kindangen, dan G. M. V Kawung, "Analisis Pengaruh Program Bantuan Pangan Non Tunai (Bpnt) Dan Program Keluarga Harapan (Pkh) Terhadap Kemiskinan Di Kabupaten Minahasa Tenggara," Jurnal Pembangunan Ekonomi dan Keuangan Daerah, vol. 21, no. 1, 2020.
- [4] N. Ikhsan, S. Kurnia Gusti, Yusra, F. Insani, dan F. Wulandari, "Implementasi Penerima Bantuan Pangan Non Tunai (Bpnt) Dengan Menggunakan Metode Genetic Modified K-Nearest Neighbori (GMKNN)," Jurnal Sains dan Informatika, vol. 8, no. 2, Des 2022, doi: 10.34128/jsi.v8i2.526.
- [5] S. Dwididanti dan D. A. Anggoro, "Analisis Perbandingan Algoritma Bisecting K-Means dan Fuzzy C-Means pada Data Pengguna Kartu Kredit," Emitor: Jurnal Teknik Elektro, vol. 22, no. 2, hlm. 110–117, Agu 2022, doi: 10.23917/emitor.v22i2.15677.
- [6] S. Kurniawan, A. M. Siregar, dan H. Y. Novita, "Penerapan Algoritma K-Means dan Fuzzy C-Means Dalam Mengelompokan Prestasi Siswa Berdasarkan Nilai Akademik," Scientific Student Journal for Information, Technology and Science, vol. IV, no. 1, Jan 2023.
- [7] B. Christian dan L. Hakim, "Penerapan Algoritma Fuzzy C-Means Pada Penentuan Lokasi Gudang Pendukung PT. XYZ," AITI: Jurnal Teknologi Informasi, vol. 16, no. Februari, hlm. 31–48, Feb 2019.
- [8] V. Herlinda dan D. Darwis, "Analisis Clustering Untuk Recredesialing Fasilitas Kesehatan Menggunakan Metode Fuzzy C-Means," Darwis, Dartono, vol. 2, no. 2, hlm. 94–99, 2021, [Daring]. Tersedia pada: <http://jim.teknokrat.ac.id/index.php/JTSI>
- [9] Aji Setiawan dan J. N. Akbar, "Implementation Fuzzy C-Means on Decision Support System BPNT (Bantuan Pangan Non-Tunai) Ministry of Social Affairs Indonesia," EMITTER International Journal of Engineering Technology, vol. 7, no. 2, hlm. 559–569, Des 2019, doi: 10.24003/emitter.v7i2.444.
- [10] K. V. Rajkumar, A. Yesubabu, dan K. Subrahmanyam, "Fuzzy clustering and Fuzzy C-Means partition cluster analysis and validation studies on a subset of CiteScore dataset," International Journal of Electrical and Computer Engineering, vol. 9, no. 4, hlm. 2760–2770, Agu 2019, doi: 10.11591/ijece.v9i4.pp2760-2770.
- [11] I. Purnama Sari dan I. Hanif Batubara, "Cluster Analysis Using K-Means Algorithm and Fuzzy C-Means Clustering for Grouping Students' Abilities in Online Learning Process," Journal of Computer Science, Information Technology and Telecommunication Engineering (JCoSITTE), vol. 2, no. 1, hlm. 139–144, 2021, doi: 10.30596/jcositte.v2i1.6504.
- [12] A. Chusyairi dan P. R. N. Saputra, "Fuzzy C-Means Clustering Algorithm For Grouping Health Care Centers On Diarrhea Disease," International Journal of Artificial Intelligence Research, vol. 5, no. 1, Jan 2021, doi: 10.29099/ijair.v5i1.191.
- [13] J. Hutagalung, D. Nofriansyah, dan M. A. Syahidan, "Implementasi Algoritma Fuzzy C-Means Clustering Sistem Crowdfunding pada Sektor Industri Kreatif Berbasis Web," JEPIN (Jurnal Edukasi dan Penelitian Informatika), vol. 6, no. 1, 2020.
- [14] J. Hutagalung, D. Nofriansyah, dan M. A. Syahdian, "Penerimaan Bantuan Pangan Non Tunai (BPNT) Menggunakan Metode ARAS," Jurnal Media Informatika Budidarma, vol. 6, no. 1, hlm. 198–207, Jan 2022, doi: 10.30865/mib.v6i1.3478.
- [15] N. Persada, R. B. Sinuhaji, I. M. Sarkis, M. Yohanna, dan H. Artikel, "Implementasi Fuzzy C-Means Program Bantuan Langsung Tunai Pada Dinas Sosial Kabupaten Deli Serdang Distribusi Kecamatan Pancur Batu," Jurnal Ilmiah Sistem Informasi, vol. 1, no. 2, hlm. 26–32, Okt 2021, [Daring]. Tersedia pada: <http://ojs.fikom-methodist.net/index.php/METHOSISFO>
- [16] Y. Hidayat, A. Nazir, R. M. Candra, S. Sanjaya, dan F. Syafria, "Clustering Vaksinasi Penyakit Mulut dan Kuku Menggunakan Algoritma Fuzzy C-Means," Journal of Computer System and Informatics (JoSYC), vol. 4, no. 3, 2023, doi: 10.47065/josyc.v4i3.3416.
- [17] A. Aziz, A. Mutoi Siregar, dan C. Zonyfar, "Penerapan Algoritma K-Means dan Fuzzy C-Means 'untuk Pengelompokan' Kabupaten Kota Berdasarkan Produksi Padi 'di' Provinsi Jawa Barat," Scientific Student Journal for Information, Technology and Science, vol. 3, no. 1, 2022.
- [18] A. Syaifudin, P. Purwanto, H. Himawan, dan M. A. Soeleman, "Customer Segmentation with RFM Model using Fuzzy C-Means and Genetic Programming," Matrik : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer, vol. 22, no. 2, hlm. 239–248, Mar 2023, doi: 10.30812/matrik.v22i2.2408.
- [19] P. Dauni, Pratiwi, dan R. Tri Prasetyo, "Pemetaan Keberlangsungan Hidup Umkm Guna Optimalisasi Bantuan Kredit Menggunakan Algoritma Fuzzy C-Means," JURNAL RESPONSIF, vol. 5, no. 1, hlm. 61–69, Feb 2023, [Daring]. Tersedia pada: <https://ejurnal.ars.ac.id/index.php/jti>
- [20] S. J. A. Sumarauw, M. G. Maukar, M. Grace Maukar, U. Negeri, dan M. Abstrak, "Fuzzy c-Means Clustering untuk Pengenalan Pola Studi kasus Data Saham Fuzzy c-Means Clustering for Pattern Recognition on Case Studies in Holdings Data," Jurnal Axioma : Jurnal Matematika dan Pembelajaran, vol. 7, no. 2, 2022.