

**Implementasi Algoritma Fuzzy C-Means dengan Particle Swarm Optimization Untuk
Pengelompokan Tingkat Kesejahteraan Di Provinsi Jawa Tengah**
*Implementation of Fuzzy C-Means Algorithm with Particle Swarm Optimization for
Welfare Level Grouping in Central Java Province*

Ulfi Rizqi Amaliah¹, Deni Arifianto², Ilham Saifudin³

¹Mahasiswa Fakultas Teknik, Universitas Muhammadiyah Jember

e-mail: amaliahulfi@gmail.com¹

^{2,3}Dosen Fakultas Teknik, Universitas Muhammadiyah Jember

Abstrak

Kesejahteraan masyarakat merupakan sebuah kondisi ketika setiap warga suatu negara selalu berada pada kondisi serba kecukupan dalam segala kebutuhannya, baik material maupun juga spiritual. Namun, adanya perbedaan kandungan sumber daya, perbedaan kondisi demografi serta pembangunan setiap wilayah menyebabkan terjadinya ketimpangan. Ketimpangan menjadi tantangan bagi setiap wilayah di Indonesia diantaranya adalah Provinsi Jawa Tengah. Salah satu cara yang dapat dilakukan untuk mengatasi ketimpangan adalah dengan melakukan pengelompokan. Proses pengelompokan dapat menggunakan metode *clustering*. Salah satu algoritma *clustering* yang dapat digunakan adalah *Fuzzy C-Means* tetapi sering sensitif pemilihan pusat *cluster* awal sehingga mudah terjebak pada optimum lokal. Terdapat beberapa algoritma yang dapat digunakan untuk mengatasi permasalahan tersebut, Salah satunya adalah *Particle Swarm Optimization*. Proses pengelompokan dilakukan dengan menggunakan 35 data pada tahun 2019 serta dilakukan pencarian cluster *optimal*. Penelitian menghasilkan *cluster* optimal pada 2 *cluster*. Pada *cluster* 1 terdapat 14 kabupaten/kota sedangkan pada *cluster* 2 terdapat 21 anggota.

Kata Kunci : kesejahteraan, *fuzzy c-means*, *particle swarm optimization*, *clustering*, *silhouettecoefficient*.

Abstract

Community welfare is a condition where every citizen of a country is always in a state of complete sufficiency in all their needs, both material and spiritual. However, differences in resource content, differences in demographic conditions and the development of each region cause inequality. Inequality is a challenge for every region in Indonesia, one of which is Central Java Province. One effort that can be done to overcome inequality is by grouping. The grouping process can use the clustering method. One of the clustering algorithms is Fuzzy C-Means but it is often sensitive to the initial cluster center so it is easy to get stuck at local optimum. There are several algorithms that can be used to overcome this problem, one of which is Particle Swarm Optimization. The grouping process was carried out using 35 data in 2019 and a search for optimal clusters was carried out. Research produces optimal clusters in 2 clusters. In cluster 1 there are 14 regencies/cities while in cluster 2 there are 21 members.

Keywords: *welfare, fuzzy c-means, particle swarm optimization, clustering, silhouette coefficient.*

1. PENDAHULUAN

Kesejahteraan masyarakat merupakan sebuah kondisi dimana setiap warga suatu negara selalu ada pada keadaan serba kecukupan dalam segala kebutuhannya. Hal tersebut baik material maupun juga spiritual (Nurfidah Dwitiyanti, Noni Selvia, 2019). Indonesia adalah negara yang secara eksplisit mengakui jika tugas utama pemerintah Republik Indonesia ialah “Memajukan kesejahteraan umum, mencerdaskan kehidupan bangsa serta mewujudkan suatu keadilan sosial bagi seluruh rakyat Indonesia”.

Berdasarkan paparan diatas, penting bagi setiap wilayah di Indonesia melakukan upaya guna meningkatkan kesejahteraan masyarakat. Namun, karena perbedaan kandungan sumber daya, perbedaan kondisi demografi serta pembangunan setiap wilayah menyebabkan terjadinya ketimpangan (Simbolon, 2017). Hal ini menjadi tantangan bagi setiap wilayah di Indonesia salah satunya ialah pada Provinsi Jawa Tengah. Menurut Badan Pusat Statistik mengenai ketimpangan pembangunan di Jawa Tengah 2017 memiliki nilai indeks ketimpangan 0,65 (nilai mendekati 1) dimana index ini masih tergolong tinggi ketimpangannya. Capaian beberapa indikator kinerja pembangunan 2018 (Sugiarto & Wibowo, 2019) juga menampilkan adanya ketimpangan indeks pembangunan dimana Kota Semarang (82,72%) memiliki nilai tertinggi dan Kabupaten Pemalang (65,67%) memiliki indeks pembangunan terendah. Salah satu cara untuk menanggulangi ketimpangan adalah dengan melakukan pengelompokan tiap bagian dari wilayah untuk mengetahui bagian wilayah mana yang mengalami kesejahteraan yang rendah sehingga mendapatkan prioritas dalam kebijakan lebih lanjut. Proses pengelompokan dapat menggunakan metode *clustering*.

Terdapat beberapa algoritma *clustering* salah satunya adalah *Fuzzy C-Means*, algoritma ini dapat digunakan untuk melakukan pengelompokan kesejahteraan. Pernyataan ini didasarkan pada penelitian sebelumnya yang dilakukan oleh (Nurfidah Dwitiyanti, Noni Selvia, 2019) dengan studi

kasus “Penerapan *Fuzzy C-Means Cluster* Dalam Pengelompokan Provinsi di Indonesia Menurut Indikator Kesejahteraan”. Peneliti tersebut menggunakan data indikator kesejahteraan tahun 2017. Pada penelitian tersebut, didapat 2 *cluster* dengan jumlah anggota pada *cluster* pertama 18 provinsi, *cluster* kedua adalah 16 provinsi. Penggunaan *Fuzzy C-Means* pada penelitian ini juga didasarkan oleh penelitian (Ramadhan, Efendi, & Mustakim, 2017) yang membandingkan performa *Fuzzy C-Means* dan *K-Means* pada data *knowledge* pelajar yang mana *Fuzzy C-Means* dengan nilai validitas (0,2854) menampilkan performa yang lebih unggul daripada *K-Means* dengan nilai (0,1866). Meskipun *Fuzzy C-Means* tergolong algoritma yang efektif dalam *clustering*, namun FCM sensitif terhadap pusat *cluster* awal sehingga mudah terjebak pada optimal lokal sehingga untuk proses selanjutnya tergantung oleh nilai awal yang di bangkitkan secara random (Siringoringo & Jamaluddin, 2019). Ada beberapa algoritma yang dapat digunakan untuk menanggulangi masalah tersebut, diantaranya adalah *Particle Swarm Optimization*. Hal ini berdasarkan penelitian dilakukan oleh (Teja, Cipta, & C-, 2018) dengan studi kasus “Optimasi PSO untuk metode *Fuzzy C-Means* dalam Pengelompokan Kelas” menunjukkan peningkatan nilai dalam validitas *cluster* yang sebelumnya pada nilai akademis dan perilaku atau sikap menghasilkan nilai validitas pada *Fuzzy C-Means* murni 0,070 sedangkan pada *Fuzzy C-Means* dengan *Particle Swarm Optimization* menunjukkan nilai validitas 0,728 sehingga terbukti *Fuzzy C-Means* dengan *Particle Swarm Optimization* berhasil membentuk *cluster* yang lebih baik..

2. PUSTAKA

A. *Clustering*

Clustering adalah sebuah metode dalam penambangan data yang digunakan sebagai pengolah data yang tidak diketahui

label maupun kelasnya. *Clustering* memiliki nama lain yang disebut *cluster analysis*.

Clustering memiliki pola kerja dimana dalam prosesnya dilakukan dengan melakukan pengelompokan sekelompok data ke dalam beberapa kelas. Objek-objek yang terdapat dalam kelas tersebut memiliki kesamaan yang tinggi apabila dibandingkan dengan objek lain yang ada pada kelas tersebut, tetapi mempunyai kesamaan yang rendah apabila dibandingkan dengan objek yang ada pada *cluster* lain (Handoko, 2016).

B. Normalisasi Data

Normalisasi data ialah sebuah langkah memberikan *range* nilai atribut dari sebuah data sehingga dapat diposisikan pada rentan tertentu (Nasution, Khotimah, & Chamidah, 2019). Dalam proses normalisasi.

Terdapat metode yang digunakan untuk normalisasi seperti normalisasi *min-max*, normalisasi *z-score*, *decimal scaling*, *Sigmoidal* dan lain-lain (Alihar, 2018).

Metode normalisasi min-man dapat dilakukan dengan rumus sebagai berikut:

$$x_j = \frac{x_i - \min(x)}{\max(x) - \min(x)} \quad (1)$$

Keterangan

x_j = data setelah normalisasi
 x_i = data ke- i
 $\text{Min}(x)$ = Nilai minimal dari atribut
 $\text{Max}(x)$ = Nilai maksimal dari atribut

C. Fuzzy C-Means

Menurut (Efiyah, 2014) *Fuzzy C-Means* merupakan sebuah algoritma *clustering* data dimana setiap data berada pada sebuah kelompok yang ditentukan nilai setiap anggotanya.

Langkah-langkah algoritma *Fuzzy C-Means* sebagai berikut (Ahmadi & Hartati, 2013):

1. Masukkan data yang hendak di klaster, berupa matriks yang berukuran $n \times m$ (n =jumlah sampel data, m = atribut setiap data). X_{ij} = data sampel ke- i ($i=1,2,\dots,n$), atribut ke- j ($j = 1,2,\dots,m$).

Menentukan :

- Jumlah klaster (c)
- Pangkat (w)
- Maksimum iterasi (MaxIter)
- Error terkecil yang diharapkan (ξ)
- Fungsi objektif awal ($P_0 = 0$)
- Iterasi awal ($t = 1$)

2. Membangkitkan bilangan secara acak μ_{ik} , $i = 1, 2, 3, \dots, n$; $k = 1, 2, 3, \dots, n$; sebagai elemen matriks partisi awal U (derajat anggota di dalam sebuah *cluster*). μ_{ik} merupakan derajat keanggotaan yang mengacu pada seberapa besar kemungkinan suatu data bisa menjadi anggota ke dalam suatu klaster. Posisi dan nilai matriks dibangun secara acak. Nilai keanggotaan ada pada interval 0 sampai dengan 1. Posisi awal matriks partisi U masih tidak akurat begitupun pusat klasternya. Sehingga kecenderungan sebuah data untuk memasuki sebuah *cluster* juga belum akurat.

Hitung setiap kolom atribut:

$$Q_j = \sum_{k=1}^c \mu_{ik}$$

Q_j adalah jumlah nilai dengan derajat keanggotaan per kolom Dengan $j = 1, 2, \dots, m$.

3. Menghitung pusat *cluster* ke- k : V_{kj} dengan $k=1, 2, 3, \dots, c$; dan $j=1, 2, 3, \dots, m$

$$V_{kj} = \frac{\sum_{i=1}^n (\mu_{ik})^w \times X_{ij}}{\sum_{i=1}^n (\mu_{ik})^w} \quad (2)$$

V_{kj} = Centroid

i = Iterasi

μ_{ik} = Perubahan matrik partisi

X_{ij} = Atribut

4. Menghitung fungsi objektif pada iterasi ke- t . Menghitung fungsi objektif digunakan untuk syarat *looping* guna memperoleh pusat klaster atau *centroid* yang tepat. Sehingga didapatkan kecenderungan data untuk masuk ke klaster mana pada langkah akhir.

$$P_t = \sum_{k=1}^c \left(\left[\sum_{j=1}^m (X_{ij} - v_{kj})^2 \right] (\mu_{ik})^w \right) \quad (3)$$

P_t = Fungsi objektif

$\sum_{i=1}^n$ = Jumlah data yang di klaster

$\sum_{k=1}^n$ = Jumlah perhitungan klaster awal

5. Menghitung perubahan matrik partisi:

$$\mu_{ik} = \frac{[\sum_{j=1}^m (X_{ij} - V_{kj})^2]^{\frac{-1}{w-1}}}{\sum_{k=1}^c [\sum_{j=1}^m (X_{ij} - V_{kj})^2]^{\frac{-1}{w-1}}} \quad (4)$$

Dengan $i=1,2,\dots,n$; dan $k=1,2,\dots,c$.

6. Memeriksa kondisi berhenti: - Jika $(|Pt - Pt-1| < \xi)$ atau $(t > \text{MaxIter})$ maka berhenti. - Jika tidak : $t = t + 1$, melangkah ke langkah empat.

D. Particle Swarm Optimization

Particle Swarm Optimization adalah metode pendekatan metaheuristik yang mencari solusi yang digambarkan seperti sebuah kelompok burung atau ikan, dalam setiap populasi mempunyai individu yang mempengaruhi sama lain. Individu yang dimaksud dikenal sebagai partikel yang dianggap seperti sebuah titik pada sebuah dimensi ruang waktu tertentu (Mansur, Prahasto, & Farikhin, 2014).

Menurut (Supianto & Mar'i, 2018) optimasi clustering pada PSO dihitung atas perpindahan posisi partikel dan *update* kecepatan untuk mengupdate pusat klaster. Adapun rumus meng-update kecepatan menggunakan persamaan berikut :

$$V_i(t) = W V_i + c_1 R_1 (X_{pi} - X_i) + c_2 R_2 (X_{gi} - X_i) \quad (5)$$

dimana:

- R_1 & R_2 = nilai acak [0,1]
- c_1 & c_2 = *Coefficient Acceleration*
- X_{pi} = nilai rata-rata data klaster
- X_{gi} = nilai rata-rata semua solusi
- X_i = data ke-i
- W = konstanta inersia
- i = 1,2,..., dimensi data
- t = iterasi

Standarisasi PSO menggunakan nilai *inersia weight* (W_{max} , W_{min}) antara 0,4 sampai 1,4 dan *coefficient acceleration* antara 1,5 sampai 2,0 (Singh, Singh, & Singh, 2012)

Untuk proses selanjutnya merupakan proses memperbarui posisi *centroid*, dengan

cara menambahkannya dengan nilai kecepatan, sesuai persamaan berikut ini :

$$X_{t+1} = X_t + V_{t+1} \quad (6)$$

E. Silhouette Coefficient

Silhouette Coefficient merupakan sebuah langkah evaluasi guna mengetahui kualitas serta kekuatan *klaster* , seberapa baik sebuah objek diposisikan pada sebuah *cluster*.

Berikut langkah-langkah dalam menghitung *Silhouette Coefficient* (Handoyo et al., 2014):

- Menghitung nilai rata-rata jarak objek dengan semua objek lain yang ada dalam satu klaster

$$a(i) = \frac{1}{[A]-1} \sum_{j \in A, j \neq i} d(i,j) \quad (7)$$

Ket :

$a(i)$: rata-rata jarak objek i ke semua objek lain di satu klaster.

$d(i,j)$: jarak antara objek i dengan objek j , dimana $i \neq j$.

$[A]$: total objek dalam klaster A

- Menghitung nilai rata-rata jarak objek dengan semua objek yang berada pada klaster lain, dan diambil nilai terkecil.

$$d(i,C) = \frac{1}{[C]} \sum_{j \in C} d(i,j) \quad (8)$$

Kemudian mencari nilai terkecilnya dengan persamaan berikut:

$$b(i) = \min_{C \neq A} d(i,C) \quad (9)$$

Keterangan:

$d(i,C)$: jarak objek i dengan klaster C.

$d(i,j)$: jarak objek i dengan objek j , dimana j anggota *klaster* C

$b(i)$: rata-rata objek dengan semua objek lain yang berada pada *klaster* C, dengan $C \neq A$.

- Menghitung nilai *silhouette coefficient* dengan persamaan berikut:

$$s(i) = \frac{b(i)-a(i)}{(a(i),b(i))} \quad (10)$$

Nilai *silhouette coefficient* mempunyai skala nilai -1 sampai 1. Apabila hasil nilai *silhouette coefficient* mendekati nilai 1, maka semakin optimal clustering data dalam satu klaster. Namun, sebaliknya jika *silhouette coefficient* mendekati nilai -1, maka semakin kurang optimal clustering data di dalam satu klaster.

3. METODOLOGI PENELITIAN

A. Pengumpulan Data

Penelitian ini menggunakan data dari Badan Pusat Statistik (BPS) Provinsi Jawa Tengah. Data yang akan diolah pada penelitian ini menggunakan data Kabupaten atau Kota di Provinsi Jawa Tengah pada tahun 2019. Terdiri dari 35 Kabupaten/Kota di Jawa Tengah. Dari data yang tersedia, peneliti menggunakan data tersebut untuk mengelompokkan kesejahteraan yang terjadi pada Kabupaten atau Kota yang ada di Provinsi Jawa Tengah. Data yang digunakan mempunyai tujuh atribut : tenaga kesehatan(TK),fasilitas kesehatan(FK), fasilitas pendidikan(FP),Pengajar(P), persentase sumber penerangan listrik(PSPL), tingkat partisipasi angkatankerja(PSPL),dan indeks pembangunan masyarakat(IPM). Atribut pada tabel fasilitas kesehatan (FK) meliputi RS umum daerah, RS bersalin daerah, poliklinik, dan puskesmas.

Tabel 1. Data Kabupaten atau Kota di Jawa timur.

Kab/Kot	TK	FK	...	IPM
Cilacap	2856	2480	...	69,6
Banyumas	4602	2580	...	71,3
Purbalingga	2069	1815	...	68,4
Banjarnegara	1702	2483	...	66,5
Kebumen	2961	1957	...	68,8
Purworejo	1905	1539	...	71,9
Wonosobo	1326	2790	...	67,8
Magelang	1536	2790	...	69,1
...
Kota Tegal	1653	244	...	74,4

Tabel 1 Data awal

Sumber : Data Awal

B. Pra-proses Data

Data yang digunakan merupakan data mentah yang nantinya masih akan diolah menggunakan cara normalisasi min-max. Setelah data mentah tersebut di normalisasi barulah data tersebut akan dilakukan perhitungan menggunakan metode *Fuzzy C-Means* dengan *particle swarm optimization*. Pada bagian ini, normalisasi data dilakukan dengan cara normalisasi *min-max*. Normalisasi *min-max* memberikan transformasi linier pada data asli namun tetap mempertahankan hubungan antar data aslinya.

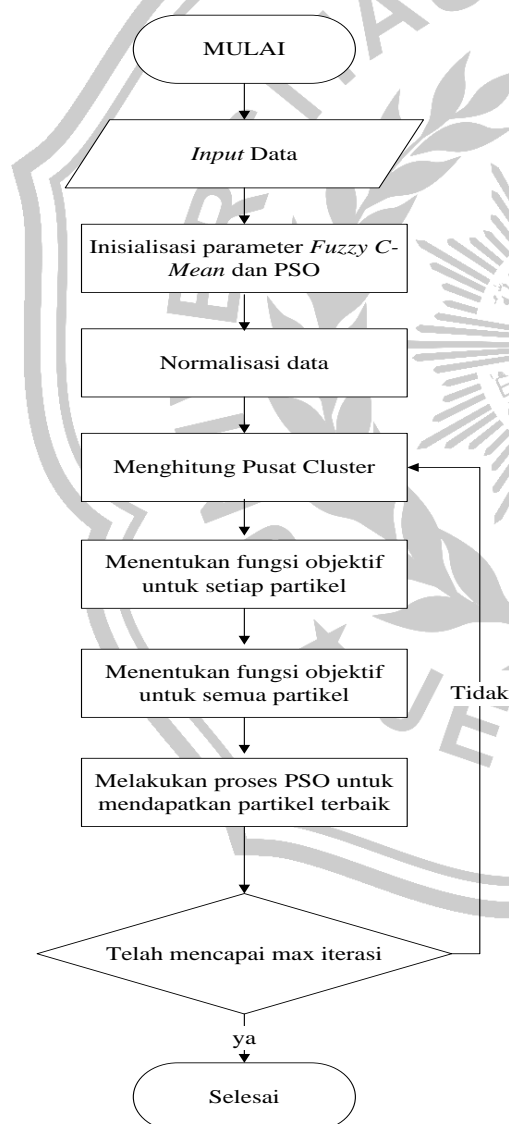
Kab/ Kota	TK	FK	IPM
Cilacap	0,192	0,883	0,228
Banyumas	0,409	0,920	0,330
Purbalingga	0,094	0,631	0,161
Banjarnegara	0,049	0,884	0,051
Kebumen	0,205	0,685	0,184
Purworejo	0,074	0,526	0,364
Wonosobo	0,002	1,000	0,126
Magelang	0,028	1,000	0,202
...
Kota Tegal	0,042	0,036	0,514

Tabel 2 Data Ternormalisasi
Sumber : Data normalisasi

C. *Fuzzy C-Means* dengan *Particle Swarm Optimization*

Diagram alur dari penerapan metode clustering menggunakan *Fuzzy C-Means* dengan *Particle Swarm Optimization* yang digunakan berdasarkan untuk menyelesaikan masalah clustering kesejahteraan pada Kabupaten pada Jawa Tengah. Sebelum masuk ke tahapan *clustering*, terlebih dahulu melakukan inialisasi parameter *fuzzy c-means* dan *particle swarm optimization*. Kemudian melakukan normalisasi data menggunakan persamaan (1). Selanjutnya akan memasuki langkah langkah *clustering* data menggunakan algoritma *Fuzzy C-Means* dengan *Particle Swarm Optimization* tahap pertama yaitu menghitung pusat *cluster* menggunakan inialisasi partikel. Tahap selanjutnya menghitung fungsi objektif untuk setiap

partikel yang melibatkan pusat kluster dan inisialisasi partikel serta melakukan perhitungan fungsi objektif untuk tiap partikel yang melibatkan update kecepatan yang menggunakan persamaan (5) dan melibatkan update partikel yang menggunakan persamaan (6) Tahap selanjutnya melakukan perubahan terhadap pusat *cluster* menggunakan kecepatan partikel baru dan posisi partikel baru, pada tahap ini iterasi +1. Proses selanjutnya melakukan pemeriksaan kondisi berhenti, jika iterasi sudah mencapai iterasi maksimal atau memenuhi kondisi berhenti seperti yang sudah dijelaskan diatas.



Gambar 1 Algoritma *Fuzzy C-Means* dengan *Particle Swarm Optimization*

D. Pengujian *Cluster Optimal*

Pada proses pengelompokan Kabupaten atau Kota menggunakan algoritma *K-Means* dengan *Particle Swarm Optimization* yang telah dilakukan pada rentang 2 *cluster* sampai 10 *cluster*. Selanjutnya akan dilakukan pengujian *cluster* optimum menggunakan *silhouette coefficient* untuk menentukan *cluster* optimum atau yang terbaik. Untuk menentukan *cluster* optimum menggunakan *silhouette coefficient* langkah pertama adalah menghitung rata-rata jarak dari suatu objek dengan semua objek lain yang berada dalam satu *cluster* menggunakan persamaan (7). Lalu Menghitung rata-rata jarak objek dengan semua objek yang berada pada *cluster* lain, dan diambil nilai terkecil menggunakan persamaan (8). Kemudian mencari nilai terkecilnya dengan persamaan (9). Proses selanjutnya menghitung nilai *silhouette coefficient* menggunakan persamaan (10).

3. HASIL DAN PEMBAHASAN

Dalam tahapan ini akan membahas tentang hasil yang telah didapatkan dari proses perhitungan yang telah dikerjakan. Data yang telah diperoleh akan di *cluster* menggunakan metode *Fuzzy C-Means* dengan *Particle Swarm Optimization* yang kemudian diolah untuk memperoleh kluster optimal atau kluster yang paling baik dengan memakai metode *Silhouette Coefficient*. Data yang dipakai yakni data pada Kabupaten/Kota di Provinsi Jawa Tengah pada tahun 2019 yang berjumlah 35 Kabupaten atau Kota.

A. Penentuan Bobot Inersia Optimal

Pengujian parameter bobot inersia dilakukan guna mendapatkan nilai maksimum inersia yang paling optimal. Nilai rata-rata terbesar merupakan nilai rata-rata yang paling optimal. Proses pengujian nilai bobot inersia maksimum dan minimum.

Nilai yang diujikan merupakan nilai Standarisasi PSO menggunakan nilai *inersia*

weight (W_{max} , W_{min}) antara 0,4 sampai 1,4 (Singh, Singh, & Singh, 2012).

Adapun hasil *output* yang didapat yaitu berupa nilai seperti pada **Tabel 3** berikut:

Bobot Inersia	Rata-Rata
0,4	0,048
0,5	0,066
0,6	0,081
0,7	0,109
0,8	0,137
0,9	0,173
1	0,152
1,1	0,142
1,2	0,121
1,3	0,111
1,4	0,094

Tabel 3. Perhitungan bobot inersia optimal

Sumber : Hasil Perhitungan bobot inersia optimal

Melalui hasil pengujian yang telah dikerjakan, telah diperoleh bobot inersia optimal [0,9] dengan nilai rata-rata *Silhouette Coefficient* 0,173. Selain itu, pada pengujian yang dilakukan juga menunjukkan adanya peningkatan nilai rata-rata *Silhouette Coefficient* pada nilai bobot inersia [0,4] sampai [0,9]. Namun, terjadi penurunan nilai rata-rata *Silhouette Coefficient* pada nilai bobot inersia [1] sampai [1,4].

B. Penentuan Jumlah *Learning Factor* Optimal

Proses ini dilakukan sama seperti pengujian bobot inersia dimana proses ini dilakukan untuk mencari *learning factor* optimal. *Learning factor* merupakan C1 dan C2 yang ada pada proses pembaruan kecepatan dan posisi partikel. Nilai *learning factor* optimum merupakan nilai rata-rata terbesar.

Nilai *learning factor* yang diujikan merupakan Standarisasi PSO dimana *coefficient acceleration* atau *learning factor* antara 1,5 sampai 2,0 (Singh, Singh, & Singh, 2012). Adapun hasil keluaran yang didapat yaitu berupa hasil seperti pada **Tabel 4** berikut :

Learning Factor	Rata-Rata
[1,5:1,6]	0,1487
[1,5:1,7]	0,1732
[1,5:1,8]	0,0986
[1,5:1,9]	0,1108
[1,5:2,0]	0,1179
[1,6:1,7]	0,1083
[1,6:1,8]	0,1038
[1,6:1,9]	0,1208
[1,6:2,0]	0,1081
[1,7:1,8]	0,1089
[1,7:1,9]	0,1076
[1,7:2,0]	0,1085
[1,8:1,9]	0,118
[1,8:2,0]	0,1168
[1,9:2,0]	0,1228

Learning Factor	Rata-Rata
[1,5:1,6]	0,1487
[1,5:1,7]	0,1732
[1,5:1,8]	0,0986
[1,5:1,9]	0,1108
[1,5:2,0]	0,1179
[1,6:1,7]	0,1083
[1,6:1,8]	0,1038
[1,6:1,9]	0,1208
[1,6:2,0]	0,1081
[1,7:1,8]	0,1089
[1,7:1,9]	0,1076
[1,7:2,0]	0,1085
[1,8:1,9]	0,118
[1,8:2,0]	0,1168
[1,9:2,0]	0,1228

Tabel 4. Perhitungan bobot inersia optimum

Sumber: Hasil Perhitungan *Learning Factor* Optimum

Untuk hasil pengujian yang telah dikerjakan, telah diperoleh jumlah *Learning Factor* Optimal untuk tingkat kesejahteraan di Jawa Tengah ialah *learning factor* [1,5:1,7] dengan nilai rata-rata *Silhouette Coefficient* 0,173. Pada pengujian parameter *learning factor* tidak ditemukan pengaruh yang signifikan karena tidak terjadi peningkatan atau penurunan nilai rata-rata *Silhouette Coefficient* yang dihasilkan

C. Penentuan *Particle* Optimum

Pengujian jumlah partikel dilakukan untuk mencari berapa jumlah partikel terbaik yang didapat dengan nilai *silhouette coefficient* tertinggi. Adapun hasil keluaran yang didapat yaitu berupa nilai seperti pada **Tabel 5** berikut:

Partikel	Rata-Rata
10	0,066
20	0,084
30	0,111
40	0,126
50	0,141
60	0,152

Partikel	Rata-Rata
70	0,134
80	0,143
90	0,145
100	0,148

Tabel 5 Penentuan *Particle* Optimal

Sumber : Hasil Perhitungan *Particle* Optimal
 Berdasarkan hasil pengujian dari tabel 5 untuk data tingkat kesejahteraan di Jawa Tengah menunjukkan jumlah partikel optimal adalah 60 partikel dengan nilai rata-rata *Silhouette Coefficient* 0,152. Pada pengujian yang dilakukan juga menunjukkan semakin banyak jumlah partikel yang diujikan maka nilai rata-rata *Silhouette Coefficient* semakin optimal. Namun pada pengujian parameter dengan 70 partikel terjadi penyimpangan nilai yang menunjukkan penurunan nilai rata-rata *Silhouette Coefficient* yang sebelumnya pada 60 partikel menunjukkan nilai rata-rata *Silhouette Coefficient* 0,152 sedangkan pada pengujian parameter dengan 70 partikel menunjukkan nilai rata-rata *Silhouette Coefficient* 0,134.

D. Penentuan Iterasi Optimal

Pengujian jumlah iterasi dilakukan guna mendapatkan nilai maksimum iterasi pada proses pencarian partikel optimal dalam proses *clustering*. Iterasi maksimum yang optimal merupakan nilai rata-rata terbesar. Adapun hasil keluaran yang didapat yaitu berupa nilai seperti pada Tabel 6 berikut:

Iterasi	Rata-Rata
10	0,063
20	0,078
30	0,111
40	0,122
50	0,138
60	0,149
70	0,155
80	0,176
90	0,152
100	0,155

Tabel 6 Penentuan Iterasi Optimal

Sumber : Hasil Perhitungan Iterasi Optimal
 Berdasarkan hasil pengujian dari tabel 6 untuk data tingkat kesejahteraan di Jawa Tengah menunjukkan nilai iterasi maksimum yang optimal adalah 80 iterasi dengan nilai rata-rata *Silhouette Coefficient* 0,176. Pada pengujian yang dilakukan juga menunjukkan semakin besar iterasi yang diujikan maka nilai rata-rata *Silhouette Coefficient* semakin optimal. Namun, pada iterasi 90 juga terjadi penyimpangan nilai rata-rata *Silhouette Coefficient* yang sebelumnya pada 80 iterasi menunjukkan nilai rata-rata *Silhouette Coefficient* 0,176 sedangkan pada pengujian parameter dengan 90 menunjukkan nilai rata-rata *Silhouette Coefficient* 0,152.

E. Penentuan Jumlah *Cluster* Optimal

Proses pengujian jumlah *cluster* bertujuan untuk memperoleh jumlah *cluster* optimal untuk setiap data yang ada. Pada proses ini jumlah *klaster* yang diujikan dimulai dari 2 sampai dengan 10 *klaster*.

Proses pengujian akan menggunakan partikel dengan jumlah 60 partikel. Nilai bobot inersia [0,9], nilai *learning factor* [1,5;1,7], serta jumlah iterasi maksimum 80 iterasi.

Adapun hasil keluaran yang didapat yaitu berupa nilai seperti pada Tabel 7 berikut:

Cluster	Rata-Rata
2	0,198
3	0,166
4	0,162
5	0,139
6	0,136
7	0,125
8	0,073
9	0,063
10	0,059

Tabel 7 Penentuan Jumlah *Cluster* Optimal

Sumber : Hasil Perhitungan *cluster* Optimal
 Berdasarkan tabel 7 hasil yang ditunjukkan jumlah *clustering* optimal untuk data tingkat kesejahteraan di Jawa Tengah yang diujikan

adalah 2 *klaster* sebesar 0,198. Selain itu, pada pengujian yang dilakukan juga menunjukkan semakin kecil *cluster* yang diujikan, maka nilai rata-rata *Silhouette Coefficient* yang dihasilkan juga semakin optimal.

F. Pengujian Perbandingan Hasil FCM dan FCMP SO

Setelah keanggotaan *cluster* optimal terbentuk, selanjutnya untuk membuktikan jika penerapan *Particle Swarm Optimization* dapat meningkatkan performa jika dibandingkan *Fuzzy C-Means* murni, maka di lakukan perbandingan dengan atau tanpa *Particle Swarm Optimization*. Pengujian *Fuzzy C-Means* tanpa *Particle Swam Optimization* dilakukan menggunakan jumlah *cluster* dan jumlah iterasi maksimal optimal yang sebelumnya telah diujikan. Pengujian dilakukan sebanyak 10 kali percobaan, kemudian akan dihitung rata-rata nilai *Silhouette Coefficient* yang dihasilkan. Berikut hasil pengujian untuk *Fuzzy C-Means* murni dengan pengujian 2 *cluster* :

Percobaan	FCM	FCM+PSO
1	0,209	0,223
2	0,223	0,249
3	0,249	0,293
4	0,091	0,199
5	0,122	0,18
6	0,056	0,26
7	0,107	0,218
8	0,139	0,196
9	0,202	0,247
10	0,151	0,211
Nilai Rata-Rata	0,1549	0,2276

Tabel 8 Perbandingan FCM dan FCMP SO
Sumber : Hasil Perhitungan Perbandingan

Berdasarkan pengujian yang di lakukan sebanyak 10 kali percobaan menghasilkan nilai rata-rata *Silhouette Coefficient*, *Fuzzy C-Means* murni menghasilkan nilai rata rata 0,1549 sedangkan *Fuzzy C-Means* dengan *Particle Swarm Optimization* menghasilkan nilai rata-rata 0,2276. Berdasarkan pengujian tersebut nilai rata-rata *Silhouette Coefficient Fuzzy C-*

Means dengan *Particle Swarm Optimization* lebih besar atau mendekati 1 jika dibandingkan dengan nilai rata-rata *Silhouette Coefficient Fuzzy C-Means* murni. Hal ini menunjukkan bahwa *Fuzzy C-Means* dengan *Particle Swarm Optimization* menghasilkan nilai *cluster* yang lebih optimal jika dibandingkan dengan *Fuzzy C-Means* murni.

4. KESIMPULAN DAN SARAN

A. Kesimpulan

Penerapan algoritma *Fuzzy C-Means* dan *Particle Swarm Optimization* untuk menentukan tingkat kesejahteraan pada Provinsi Jawa Tengah juga menghasilkan nilai Parameter yang optimum, dimana jumlah partikel optimum adalah 60 partikel, untuk nilai bobot inersia optimum adalah [0,9] dengan, untuk nilai optimum learning factor adalah [1,5:1,7] dengan nilai, sedangkan maksimum iterasi yang paling optimum adalah 80 iterasi.

Penerapan algoritma *Fuzzy C-Means* dengan *Particle Swarm Optimization* untuk menentukan tingkat kesejahteraan pada Provinsi Jawa Tengah menghasilkan *klaster 2* sebagai *klaster* yang optimum.

Pengelompokan tingkat kesejahteraan pada Provinsi Jawa Tengah ialah 154 Kabupaten atau Kota untuk *klaster 1* dan 21 Kabupaten atau Kota untuk *klaster 2*.

Pengujian perbandingan hasil rata-rata nilai *Silhouette Coefficient* FCMP SO dan FCM menghasilkan nilai rata-rata *Silhouette Coefficient* FCMP SO lebih tinggi jika di bandingkan dengan rata-rata FCM. Hal ini dapat disimpulkan bahwa penerapan PSO berhasil meningkatkan performa FCM.

B. Saran

Memilih parameter yang tepat: Kedua algoritma ini memerlukan pengaturan parameter yang akan di gunakan guna memberikan hasil yang optimal. Oleh karena itu, perlu melakukan eksperimen untuk menemukan parameter yang cocok untuk masalah yang akan diselesaikan.

5. REFERENSI

- Ahmadi, A., & Hartati, S. (2013). Penerapan Fuzzy C-Means dalam Sistem Pendukung Keputusan untuk Penentuan Penerima Bantuan Langsung Masyarakat (BLM) PNPM- MPd (Studi Kasus PNPM-MPd Kec . Ngadirojo Kab . Pacitan) 2007 Pemerintah Indonesia mencanangkan Program Nasional Pemberdayaan Mas. *Berkala MIPA*, 23(3), 264–273.
- Bisilisin, F. Y., Herdiyeni, Y., & Silalahi, B. I. B. P. (2014). Optimasi K-Means Clustering Menggunakan Particle Swarm Optimization pada Sistem Identifikasi Tumbuhan Obat Berbasis Citra K-Means Clustering Optimization Using Particle Swarm Optimization on Image Based Medicinal Plant Identification System. *Ilmu Komputer Agri-Informatika*, 3(2002), 38–47.
- Efiyah, U. (2014). *Penerapan algoritma*. 217–224.
- Fitri, R. K. R., Rahmansyah, A., & Darwin, W. (2017). Penggunaan Bahasa Pemrograman Python Sebagai Pusat Kendali Pada Robot 10-D. *5th Indonesian Symposium on Robotic Systems and Control*, 23–26.
- Handoko, K. (2016). Penerapan Data Mining Dalam Meningkatkan Mutu Pembelajaran Pada Instansi Perguruan Tinggi Menggunakan Metode K-Means Clustering (Studi Kasus Di Program Studi Tkj Akademi Komunitas Solok Selatan). *Jurnal Teknologi dan Sistem Informasi*, 02(03), 31–40. Diambil dari <http://teknosi.fti.unand.id/index.php/teknosi/article/view/70>
- Handoyo, R., Mangkudjaja, R., & Nasution, S. M. (2014). Perbandingan Metode Clustering Menggunakan Metode Single Linkage dan K - Means pada Pengelompokan Dokumen. *Jurnal SIFO Mikroskil*, 15(2), 73–82. <https://doi.org/10.55601/jsm.v15i2.161>
- Mansur, M., Prahasto, T., & Farikhin, F. (2014). Particle Swarm Optimization Untuk Sistem Informasi Penjadwalan Resource Di Perguruan Tinggi. *Jurnal Sistem Informasi Bisnis*, 4(1), 11–19. <https://doi.org/10.21456/vol4iss1pp11-19>
- Nahdliyah, M. A., Widiharih, T., & Prahutama, A. (2019). METODE k-MEDOIDS CLUSTERING DENGAN VALIDASI SILHOUETTE INDEX DAN C-INDEX (Studi Kasus Jumlah Kriminalitas Kabupaten/Kota di Jawa Tengah Tahun 2018). *Jurnal Gaussian*, 8(2), 161–170. <https://doi.org/10.14710/j.gauss.v8i2.26640>
- Nasution, D. A., Khotimah, H. H., & Chamidah, N. (2019). Perbandingan Normalisasi Data untuk Klasifikasi Wine Menggunakan Algoritma K-NN. *Computer Engineering, Science and System Journal*, 4(1), 78. <https://doi.org/10.24114/cess.v4i1.11458>
- Ndakularak E., Nyoman Djinar Setiawina, I. K. D. (2014). Analisis Faktor-Faktor yang Mempengaruhi Kesejahteraan Masyarakat Kabupaten/Kota di Provinsi Bali. *E-Jurnal Ekonomi dan Bisnis Universitas Udayana*, 2(2), 140–153.
- Nurfidah Dwitiyanti, Noni Selvia, F. R. A. (2019). *Penerapan Fuzzy C-Means Cluster Dalam Pengelompokan Provinsi Indonesia Menurut Indikator Kesejahteraan Rakyat Pembangunan suatu negara dapat dinilai dari semakin naik atau tidaknya kesejahteraan rakyatnya . Kesejahteraan dapat diartikan sebagai suatu kead*. 12(3), 201–209.
- Permana, I., & Nur Salisah, F. (2022). The Effect of Data Normalization on the Performance of the Classification Results of the Backpropagation Algorithm. *Ijrse*, 2(1), 67–72. Diambil dari <https://media.neliti.com/media/publications/485639-pengaruh-normalisasi-data-terhadap-perfo-e19e3a00.pdf>
- Ramadhan, A., Efendi, Z., & Mustakim. (2017). Perbandingan K-Means dan

- Fuzzy C-Means untuk Pengelompokan Data User Knowledge Modeling. *Seminar Nasional Teknologi Informasi, Komunikasi dan Industri (SNTIKI) 9*, 219–226.
- Shoolihah, A.-M., Furqon, M. T., & Widodo, A. W. (2017). Implementasi Metode Improved K-Means untuk Mengelompokkan Titik Panas Bumi. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer (J-PTIIK) Universitas Brawijaya*, 1(11), 1270–1276.
- Simbolon, T. R. (2017). *Analisa Keterkaitan Ketimpangan Pembangunan Antar Daerah Terhadap Pertumbuhan Ekonomi di Wilayah Sumatera*.
- Singh, N., Singh, S., & Singh, S. B. (2012). *Hps0 : a New Version of Particle Swarm Optimization Algorithm*. 3(3), 123–134.
- Siringoringo, R., & Jamaluddin, J. (2019). Peningkatan Performa Cluster Fuzzy C-Means pada Klastering Sentimen Menggunakan Particle Swarm Optimization. *Jurnal Teknologi Informasi dan Ilmu Komputer*, 6(4), 349. <https://doi.org/10.25126/jtiik.2019641090>
- Sugiarto, S., & Wibowo, W. (2019). Klasterisasi Kabupaten/Kota Di Jawa Tengah Berdasarkan Indikator Kinerja Pembangunan. *Jurnal Litbang Sukowati : Media Penelitian dan Pengembangan*, 3(2), 14. <https://doi.org/10.32630/sukowati.v3i2.161>
- Teja, M., Cipta, A., & C-, F. (2018). *C-Means Dalam Pengelompokan Kelas*. 11(1), 72–91.
- Waluyo, J., Teknik, F., & Magelang, U. M. (2019). *Penerapan Metode K-means Clustering Dalam Penilaian Kedisiplinan Siswa Untuk Layanan Bimbingan Dan Konseling Di SMP Negeri 3 Temanggung*.