

## BAB III

### METODOLOGI PENELITIAN

Pada penyelesaian *geodemographic analysis* (GDA), teknik *clustering* dibutuhkan untuk menemukan pola perilaku dari setiap daerah sehingga kemudian dapat dibentuk kelompok atau klaster sesuai dengan karakteristik daerah tersebut. Teknik *clustering* yang umumnya digunakan adalah *fuzzy clustering* (Pamungkas dan Pramana, 2018). Berikut algoritma *fuzzy clustering* yang digunakan untuk menyelesaikan *Geo-demographic Analysis* (GDA).

#### 3.1. Fuzzy C-Means (FCM)

Pada tahun 1973, Dunn memperkenalkan metode FCM untuk pertama kalinya, kemudian tahun 1981 Bezdek, et.al mengembangkan konsep FCM sebagai salah satu algoritma dari *fuzzy clustering* yang memiliki tujuan untuk meminimumkan fungsi objektif pada persamaan berikut (Klir dan Yuan, 2019).

$$J_{FCM}(U, V; X) = \sum_{k=1}^n \sum_{i=1}^c [u_{ik}]^m \|x_i - v_k\|^2 \quad (3.1)$$

$$v_k = \frac{\sum_{i=1}^n [u_{ik}]^m x_i}{\sum_{i=1}^n [u_{ik}]^m} \quad (3.2)$$

$$u_{ik} = \left[ \sum_{j=1}^c \left( \frac{\|x_i - v_k^{(t)}\|^2}{\|x_i - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right]^{-1} \quad (3.3)$$

dengan,

n : banyak data,

c : banyak klaster,

m : bobot,

t : iterasi atau pengulangan,

$u_{ik}$  : nilai keanggotaan data ke- i pada klaster ke- k dan  $u_{ik} \in [0,1]$ ,

$x_i$  : data ke- i,

$v_k$  : *centroid* (titik pusat) pada klaster ke- k,

U : himpunan dari nilai keanggotaan,

V : himpunan dari *centroid*,

X : himpunan data.

Pada penyelesaiannya, dalam meminimumkan fungsi objektif tersebut, terdapat dua persamaan yang harus dipenuhi, yaitu sebagai berikut:

$$\sum_{k=1}^c u_{ik} = 1 \quad (3.4)$$

$$0 < \sum_{i=1}^n u_{ik} < n \quad (3.5)$$

Persamaan 3.4 menyatakan bahwa jumlah nilai keanggotaan data ke-  $i$  terhadap semua kluster adalah 1 (satu). Kemudian, persamaan 3.5 menyatakan bahwa tidak ada kluster yang kosong. Berikut langkah-langkah penyelesaian FCM (Klir dan Yuan, 1995).

a. Langkah 1

Pada  $t = 0$  misalkan nilai dari  $n$ ,  $c$ ,  $m$ ,  $\varepsilon$ , maksimum iterasi ( $t$ ), dan  $u_{ik}$ . Nilai  $u_{ik}$  dipilih secara acak pada rentang  $[0,1]$  kemudian disesuaikan dengan persamaan 3.4.

b. Langkah 2

Hitung nilai *centroid* menggunakan persamaan 3.2.

c. Langkah 3

Perbarui nilai dari  $u_{ik}$  dengan menggunakan persamaan 3.3.

d. Langkah 4

Ulangi Langkah 2 dan 3, kemudian hentikan proses pengulangan jika  $|u_{ik}^{(t+1)} - u_{ik}^{(t)}| \leq \varepsilon$  atau sudah mencapai maksimum  $t$ .

Pada penentuan nilai  $m$ , tidak ada teori yang memberikan suatu ketentuan khusus mengenai berapa nilai yang harus dipilih sehingga yang perlu diperhatikan adalah  $m \in (1, \infty)$ . Kemudian, pemilihan kluster suatu data ditentukan berdasarkan nilai keanggotaan terbesar.

$$\max\{u_{ik} \mid 1 \leq k \leq c\} \quad (3.6)$$

Pada prosesnya FCM tidak melibatkan efek geografis seperti jarak antar suatu wilayah, sementara GDA memerlukan efek geografis dalam

penyelesaiannya sehingga FCM tidak dapat digunakan untuk menyelesaikan GDA.

### 3.2. Fuzzy Clustering dan Neighborhood Effect

Pada tahun 1998, Feng dan Flowerdew membuat algoritma baru yang menggabungkan *fuzzy clustering* dan *neighborhood effect* (Mason dan Jacobson, 2007).

Feng dan Flowerdew menambahkan *neighborhood effect* berupa jarak dan panjang batas umum dua daerah yang merupakan efek geografis ke dalam fungsi keanggotaan sehingga terbentuk fungsi keanggotaan baru yang berbeda dari fungsi keanggotaan FCM yang didefinisikan sebagai berikut (Mason dan Jacobson, 2007):

$$u_i' = \alpha u_i + \beta \frac{1}{A} \sum_{j=1}^n w_{ij} u_j \quad (3.7)$$

$$\alpha + \beta = 1 \quad (3.8)$$

$$w_{ij} = \frac{P_{ij}^b}{d_{ij}^a} \quad (3.9)$$

dengan,

$u_i'$ : nilai keanggotaan baru dari daerah ke- i pada suatu klaster,

$u_i$ : nilai keanggotaan lama dari daerah ke-i pada suatu klaster,

$\alpha$  : faktor pengali untuk nilai keanggotaan lama,

$\beta$  : faktor pengali untuk nilai penimbang,

A : nilai untuk memastikan nilai penimbang tidak lebih dari 1 (satu),

n : banyak data,

$w_{ij}$ : nilai penimbang interaksi dua daerah,

$P_{ij}$ : panjang batas antara daerah i dan daerah j,

$d_{ij}$ : jarak antara daerah i dan daerah j,

Namun menurut Mason dan Jacobson, pada pembaruan algoritma yang dijelaskan oleh Feng dan Flowerdew terdapat efek geografis yang tidak dilibatkan, yaitu populasi pada suatu daerah sehingga untuk menyelesaikan GDA tidak dapat menggunakan algoritma ini.

### 3.3. Fuzzy Geographically Weighted Clustering (FGWC)

Pada tahun 2007, Mason dan Jacobson memperkenalkan metode FGWC untuk pertama kalinya. FGWC merupakan perbaikan dari algoritma FCM yang telah melibatkan efek geografis seperti jarak dan jumlah populasi dua daerah pada fungsi keanggotaannya sehingga diperoleh fungsi keanggotaan baru yang berbeda dengan fungsi keanggotaan pada metode FCM. Pada mulanya, fungsi objektif yang digunakan dalam FGWC serupa dengan fungsi objektif pada metode FCM, yaitu pada persamaan (3.1). Kemudian, terdapat modifikasi karena pada *data set* yang berisi  $n$  jumlah data dan  $d$  jumlah variabel (dimensi) terdapat dua fungsi objektif yang berbeda. Jika  $n > d$ , maka fungsi objektif dengan parameter nilai keanggotaan dapat mempermudah proses penyelesaian. Namun, jika  $n \leq d$  maka fungsi objektif dengan parameter *centroid* (titik pusat klaster) dapat mempermudah proses penyelesaian (Wijayanto, 2015). Oleh karena itu, diperlukan modifikasi dari persamaan (3.1) dengan bantuan persamaan (3.2), (3.3), dan diperoleh dua fungsi objektif sebagai berikut:

$$J_{FGWC}(U; X) = \sum_{i=1}^n \sum_{k=1}^c [u_{ik}]^m \left\| x_i - \frac{\sum_{j=1}^n [u_{jk}]^m x_j}{\sum_{j=1}^n [u_{jk}]^m} \right\|^2 \quad (3.10)$$

$$J_{FGWC}(V; X) = \sum_{i=1}^n \sum_{k=1}^c \frac{\|x_i - v_k\|^2}{\left[ \sum_{j=1}^c \left( \frac{\|x_i - v_k^{(t)}\|^2}{\|x_i - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}} \right]^m} \quad (3.11)$$

dengan,

$n$  : banyak data,

$c$  : banyak klaster,

$u_{ik}$ : nilai keanggotaan lama dari daerah ke- $i$  pada klaster ke- $k$ ,

$m$  : bobot,  $m \in (1, \infty)$ ,

$x_i$  : data ke-  $i$ ,

$v_k$  : *centroid* (titik pusat) pada klaster ke-  $k$ ,

$t$  : indeks iterasi atau pengulangan.

Persamaan (3.10) disebut dengan FGWC-U dan persamaan (3.11) disebut dengan FGWC-V. Jika  $n > d$  maka fungsi objektif yang digunakan adalah FGWC-V dan jika  $n < d$  maka fungsi objektif yang digunakan adalah FGWC-U. Kemudian, fungsi keanggotaan pada persamaan (3.3) merupakan fungsi keanggotaan sebelum adanya modifikasi geografi, sedangkan pada metode FGWC fungsi keanggotaan yang digunakan adalah fungsi keanggotaan yang sudah mendapatkan modifikasi geografis, yaitu sebagai berikut (Mason dan Jacobson, 2007):

$$u_i' = \alpha u_i + \beta \frac{1}{A} \sum_{j=1}^n w_{ij} u_j \quad (3.12)$$

$$\alpha + \beta = 1 \quad (3.13)$$

$$w_{ij} = \frac{(m_i m_j)^b}{d_{ij}^a} \quad (3.14)$$

dengan,

$u_i'$ : nilai keanggotaan baru dari daerah ke- i pada suatu klaster,

$u_i$ : nilai keanggotaan lama dari daerah ke-i pada suatu klaster,

$\alpha$  : faktor pengali untuk nilai keanggotaan lama,

$\beta$  : faktor pengali untuk nilai penimbang,

$A$  : nilai untuk memastikan nilai penimbang tidak lebih dari 1 (satu),

$w_{ij}$ : nilai penimbang interaksi dua daerah,

$m_i$ : populasi pada daerah i,

$d_{ij}$ : jarak antara daerah i dan daerah j,

FGWC memiliki tahapan penyelesaian yang hampir sama dengan FCM, termasuk tahap pertama mengenai pemilihan nilai keanggotaan secara acak. Pemilihan nilai keanggotaan secara acak dapat menyebabkan solusi terjebak pada lokal optimum, artinya solusi yang diperoleh merupakan solusi terbaik yang dimiliki oleh masing-masing daerah sehingga tidak membandingkan dengan solusi daerah lain yang mungkin memiliki karakteristik yang sama dengan daerah tersebut. Oleh karena itu, FGWC membutuhkan suatu metode optimasi yang dapat membantu memperoleh solusi global optimum.

### 3.4. Metode Metaheuristik

Istilah metaheuristik pertama kali diperkenalkan oleh Glover tahun 1986, yang merupakan gabungan dua kata yang berasal dari Bahasa Yunani, yaitu *heuristik* yang berarti “untuk mencari/menemukan berdasarkan *trial and error*” dan *meta* yang berarti “pada tingkat yang lebih tinggi” (Yang, 2010). Glover menyatakan bahwa metaheuristik adalah metode solusi yang mengatur interaksi antara prosedur perbaikan lokal dan strategi pada tingkat yang lebih tinggi untuk menciptakan algoritma yang dapat membantu ke luar dari lokal optimum dan melakukan pencarian yang *robust* pada ruang pencarian (Blum dan Roli, 2003).

Pada algoritma metaheuristik terdapat dua komponen utama yang perlu diperhatikan, yaitu diversifikasi dan intensifikasi, di mana kedua komponen tersebut perlu seimbang. Diversifikasi merujuk pada kemampuan untuk menemukan solusi pada ruang pencarian. Sementara itu, intensifikasi merujuk pada kemampuan untuk meningkatkan solusi menjadi lebih baik dari solusi yang telah dicapai sebelumnya (Blum dan Roli, 2003). Diversifikasi yang besar dapat meningkatkan peluang untuk menemukan solusi global optimum, tetapi dapat mengurangi efisiensi, sedangkan intensifikasi yang besar biasanya dapat membuat algoritma terjebak pada lokal optimum (Yang, et.al, 2014). Salah satu algoritma metaheuristik adalah *particle swarm optimization* (PSO) (Abdussamad, et.al, 2020).

#### 3.3.1. Particle Swarm Optimization (PSO)

*Particle Swarm Optimization* (PSO) dikembangkan oleh Eberhart dan Kennedy pada tahun 1995 (Bansal, et.al, 2011). PSO merupakan salah satu metode metaheuristik yang terinspirasi dari perilaku/kebiasaan hewan, serangga, dan manusia (Gendreau dan Potvin, 2010). Saat sekawanan hewan mencari makan, setiap anggota cenderung berpencar dan kemudian mengikuti anggota lain yang memiliki posisi dekat dengan lokasi makanan (solusi). Jika dianalogikan, kawanan dapat disebut dengan populasi dan anggota dapat disebut dengan individu (Wijayanto, 2015). Posisi dan kecepatan populasi dari  $n$  individu dengan iterasi (pengulangan) ke-  $i$  dinotasikan sebagai berikut:

$$x_i = (x_{1i}, x_{2i}, \dots, x_{ni}) \quad (3.15)$$

$$v_i = (v_{1i}, v_{2i}, \dots, v_{ni}) \quad (3.16)$$

Pada setiap iterasi posisi setiap individu disesuaikan berdasarkan kecepatan dan perbedaan antara posisi saat ini dan posisi terbaik populasi, juga posisi terbaik individu sehingga pergerakan setiap individu untuk memperoleh solusi optimal ditentukan melalui hubungan posisi dan kecepatan, posisi terbaik individu, dan posisi terbaik populasi (Gendreau dan Potvin, 2010).

$$v_i(t+1) = v_i(t) + c_1 \text{rand}() (p_i - x_i(t)) + c_2 \text{rand}() (p_g - x_i(t)) \quad (3.17)$$

$$x_i(t+1) = v_i(t+1) + x_i(t) \quad (3.18)$$

dengan,

$v_i(t+1)$  : kecepatan individu ke-i pada iterasi ke (t+1),

$x_i(t+1)$  : posisi individu ke-i pada iterasi ke (t+1),

$c_1$  dan  $c_2$  : percepatan konstan yang bernilai positif, umumnya  $c_1 = c_2$   
(Bansal, et.al, 2011),

$t$  : iterasi atau pengulangan,

$\text{rand}()$  : angka acak pada rentang [0,1],

$p_i$  : posisi terbaik individu,

$p_g$  : posisi terbaik populasi,

Berikut langkah-langkah penemuan solusi optimum dengan menggunakan PSO (Parsopoulos dan Vrahatis, 2010).

a. Langkah 1

Misalkan fungsi objektif yang akan digunakan, nilai  $c_1$ , dan nilai  $c_2$ .

b. Langkah 2

Inisialisasi posisi awal dan kecepatan sejumlah n individu.

c. Langkah 3

Hitung nilai fungsi objektif berdasarkan posisi setiap individu.

d. Langkah 4

Tentukan posisi individu terbaik berdasarkan nilai fungsi objektif pada iterasi ke-t-1 dan t, kemudian tentukan posisi terbaik populasi.

e. Langkah 5

Tentukan nilai posisi dan kecepatan selanjutnya menggunakan persamaan 3.17 dan 3.18.

f. Langkah 6

Ulangi langkah 3 sampai 5 hingga tujuan terpenuhi.

PSO merupakan salah satu metode metaheuristik sehingga diversifikasi dan intensifikasi merupakan dua komponen yang penting dalam PSO, untuk menyeimbangkan kedua komponen tersebut, Shi dan Eberhart (1998) menambahkan variabel *inertia weight* atau penimbang inersia ke dalam persamaan 3.17 sehingga diperoleh persamaan baru sebagai berikut:

$$v_i(t + 1) = \omega v_i(t) + c_1 \text{rand}() (p_i - x_i(t)) + c_2 \text{rand}() (p_g - x_i(t)) \quad (3.19)$$

dengan  $\omega$  sebagai penimbang inersia.

### 3.3.1.1. *Linear Decreasing Inertia Weight (LD)*

Penimbang inersia pertama kali diperkenalkan oleh Shi dan Eberhart pada tahun 1998. Penimbang inersia dapat membantu PSO untuk menyeimbangkan diversifikasi dan intensifikasi (Bansal, et.al, 2011). Pada mulanya, Shi dan Eberhart membuat penimbang inersia pertama yang disebut *Constant Inertia Weight*, kemudian beberapa peneliti mulai tertarik dengan penimbang inersia sehingga saat ini terdapat 15 penimbang inersia sebagai berikut (Bansal, et.al, 2011):

1. *Constant Inertia Weight.*
2. *Random Inertia Weight.*
3. *Adaptive Inertia Weight.*
4. *Sigmoid Inertia Weight.*
5. *Sigmoid Decreasing Inertia Weight.*
6. *Linear Decreasing Inertia Weight.*
7. *The Chaotic Inertia Weight.*
8. *Chaotic Random Inertia Weight.*
9. *Oscillating Inertia Weight.*
10. *Global-Local Inertia Weight.*
11. *Simulated Annealing Inertia Weight.*
12. *Natural Exponent Inertia Weight Strategy (e 1-PSO).*

13. *Natural Exponent Inertia Weight Strategy* (e 2-PSO).

14. *Logarithm Decreasing Inertia Weight*.

15. *Exponent Decreasing Inertia Weight*.

Menurut Bansal (2011) dan Hadi (2017) penimbang inersia terbaik dalam meminimumkan kesalahan (*error*) adalah *Linear Decreasing Inertia Weight* (LD) sehingga pada penelitian ini menggunakan LD untuk membantu menyeimbangkan diversifikasi dan intensifikasi pada PSO. LD digunakan dalam mencari kecepatan individu pada iterasi ke-  $t+1$  pada persamaan 3.19, nilai LD ( $\omega$ ) diperoleh dari persamaan berikut.

$$\omega_t = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{t_{max}} t \quad (3.20)$$

dengan,

$\omega_t$  : penimbang inersia pada iterasi ke-  $t$ ,

$t_{max}$  : maksimum iterasi yang ditentukan,

$t$  : iterasi atau pengulangan.

Berdasarkan penelitian yang dilakukan oleh Bansal, penimbang inersia yang membantu PSO sehingga memperoleh hasil terbaik berkisar pada rentang  $0,4 < \omega < 0,9$  sehingga ditentukan nilai  $\omega_{max} = 0,9$  dan nilai  $\omega_{min} = 0,4$ .

### 3.5. *Context-Based*

Metode FGWC yang dibuat oleh Mason dan Jacobson memiliki keterbatasan dalam kecepatan perhitungan yang disebabkan oleh proses modifikasi keanggotaan kluster dilakukan pada tiap iterasi (Son, et.al, 2012). *Context based algorithm* digunakan dengan tujuan untuk mempercepat proses algoritma (Minh dan Son, 2015). *Context variable* didefinisikan dengan tujuan untuk membatasi *dataset* berdasarkan beberapa kondisi dalam dimensi tertentu.

Misalkan diberikan *dataset* dengan  $N$  atribut,  $X = \{X_1, X_2, \dots, X_N\}$ . *Dataset* diklusterisasikan ke dalam  $c$  kluster dengan ruang dimensi ( $X \in R^r$ ), Tujuan dari CFGWC adalah untuk mengklusterisasi data ke dalam  $c$  kluster dan  $V_i$  adalah titik pusat kluster ke- $i$ . *Context variable* didefinisikan sebagai berikut:

$$A : Y \rightarrow [0,1] \quad (3.21)$$

$$y_k \rightarrow f_k = A(y_k) \quad (3.22)$$

$f_k$  merepresentasikan hubungan antara data ke-  $k$  dan *context*  $Y$ . Terdapat beberapa cara untuk mendefinisikan korelasi antara  $f_k$  dan nilai keanggotaan data ke- $k$  pada kluster ke- $i$  , yaitu dapat menggunakan persamaan 3.23 atau 3.24.

$$\sum_{i=1}^c u_{ik} = f_k ; k = [1, N] \quad (3.23)$$

$$\max\{u_{ik} | 1 \leq k \leq c\} = f_k \quad (3.24)$$

Matriks partisi  $U$  didefinisikan pada persamaan berikut (Minh dan Son, 2015).

$$U(f) = \left\{ u_{ik} \in [0,1] : \sum_{i=1}^c u_{ik} = f_k, \quad \forall k = 1, \dots, N; \sum_{k=1}^N u_{ik} < N \right\} \quad (3.25)$$

Berikut langkah-langkah metode *context-based clustering* (Minh dan Son, 2015).

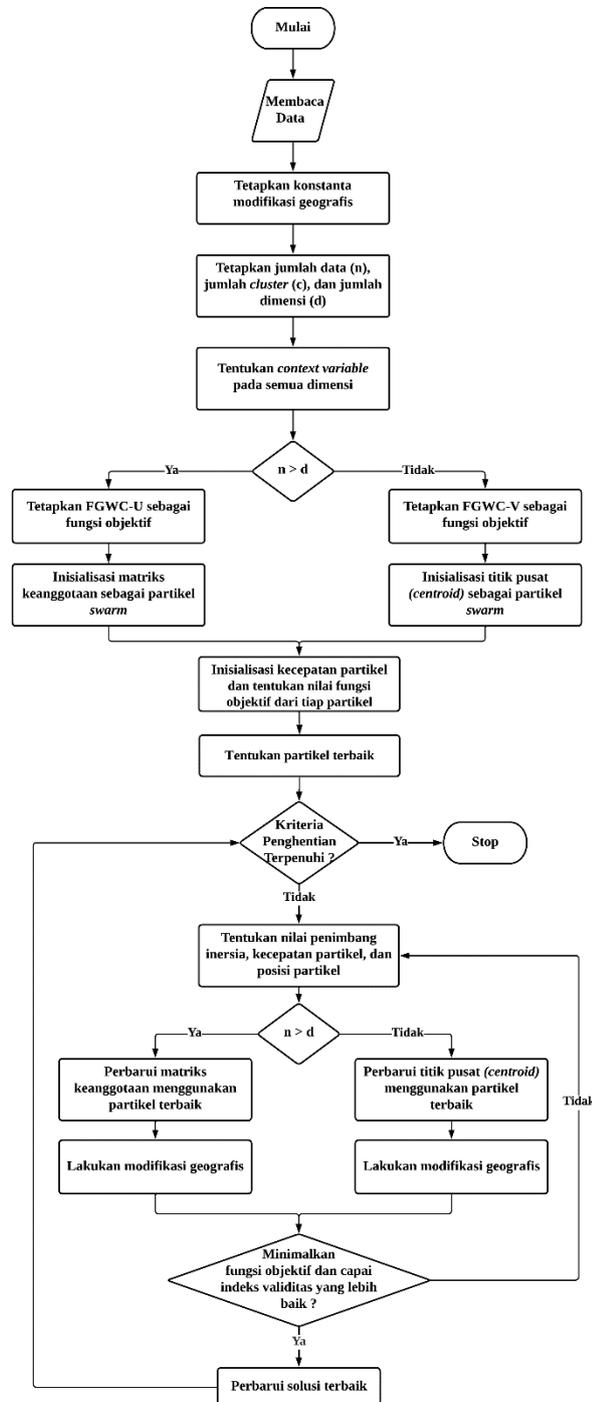
1. Inisialisasi matriks  $U(t)$  pada  $t=0$ .
2. Hitung titik pusat kluster berdasarkan persamaan 3.2.
3. Hitung matriks  $U(t+1)$  menggunakan persamaan berikut.

$$u_{ik} = \frac{f_k}{\sum_{j=1}^c \left( \frac{\|x_i - v_k^{(t)}\|^2}{\|x_i - v_j^{(t)}\|^2} \right)^{\frac{1}{m-1}}} ; k = [1, N]; i = [1, c] \quad (3.26)$$

4. Sesuaikan matriks partisi dengan modifikasi geografis pada persamaan 3.12.

### 3.6. Modifikasi Metode CFGWC-PSO-LD

Secara umum tahapan analisis CFGWC PSO-LD secara singkat diuraikan oleh diagram alir pada gambar 3.1 sebagai berikut (Wijayanto, 2015):



Gambar 3. 1 Diagram Alir Metode CFGWC-PSO-LD

### 3.7. Metode CFGWC-PSO-LD

Metode FGWC (*fuzzy geographically weighted clustering*) digunakan untuk memperoleh klaster daerah dengan kesamaan karakteristik penyebab terjadinya *stunting*. Pada tahap awal penyelesaian FGWC, terdapat inisialisasi nilai keanggotaan secara acak yang dapat menyebabkan solusi terjebak pada lokal optimum sehingga metode PSO-LD digunakan untuk menangani masalah solusi lokal optimum tersebut.

Adapun langkah-langkah analisis data menggunakan metode FGWC-PSO-LD adalah sebagai berikut:

1. Masukkan data, kemudian setelah data dibaca, tentukan jumlah klaster ( $c$ ), *threshold* ( $\varepsilon > 0$ ), jumlah variabel (dimensi  $d$ ), dan *fuzziness*  $m$ . Misalkan konstanta PSO, seperti maksimum iterasi ( $t_{max}$ ) dan jumlah partikel *swarm*. Misalkan konstanta pada modifikasi geografis, yaitu  $\alpha$ ,  $\beta$ ,  $a$ , dan  $b$ .
2. Tentukan *context variable* menggunakan persamaan 3.26 pada semua variabel.
3. Jika  $n > d$  maka gunakan persamaan 3.10 sebagai fungsi objektif dan inisialisasi matriks keanggotaan sebagai partikel *swarm*, sedangkan jika  $n \leq d$  maka gunakan persamaan 3.11 sebagai fungsi objektif dan inisialisasi titik pusat klaster (*centroid*) sebagai partikel *swarm*. Metode penghitungan jarak yang digunakan pada metode ini adalah *Euclidean*.
4. Inisialisasi kecepatan *swarm* dan tentukan nilai fungsi objektif dari tiap partikel. Kemudian tentukan partikel terbaik.
5. Tinjau apakah proses iterasi telah mencapai maksimum atau solusi telah mencapai global optimum.
6. Jika kriteria penghentian belum tercapai, maka lanjutkan iterasi dengan menghitung penimbang inersia dengan menggunakan persamaan 3.20, perbarui kecepatan partikel dengan menggunakan persamaan 3.19, dan perbarui posisi partikel dengan menggunakan persamaan 3.18. Tentukan *swarm* baru dan gunakan sebagai *input* fungsi objektif untuk menghitung titik pusat klaster (*centroid*).
7. Lakukan modifikasi geografis melalui persamaan 3.12, 3.13, 3.14 untuk melibatkan efek geografis.

8. Perbarui posisi terbaik tiap partikel. Jika fungsi objektif telah mencapai nilai paling minimum, maka solusi terbaik berasal dari iterasi saat ini. Namun, jika tidak ada perbaikan fungsi objektif atau dengan kata lain fungsi objektif pada iterasi sebelumnya memiliki nilai yang lebih kecil, maka gunakan solusi dari iterasi sebelumnya.
9. Tinjau apakah iterasi sudah mencapai iterasi maksimum yang ditentukan atau apakah  $|u_{ik}^{(t+1)} - u_{ik}^{(t)}| \leq \varepsilon$  atau apakah nilai  $IFV^{(t+1)} > IFV^{(t)}$ , jika memenuhi salah satu keadaan tersebut, maka hentikan iterasi. Namun, jika tidak memenuhi seluruh keadaan tersebut, maka ulangi dari langkah 6.

### 3.8. Sumber Data

Penelitian ini menggunakan data sekunder yang diperoleh dari IPKM (Indeks Pembangunan Kesehatan Masyarakat) tahun 2018 yang di keluarkan oleh Kemenkes RI. Tujuan penyusunan IPKM sebagai salah satu alat monitor keberhasilan pembangunan kesehatan masyarakat melalui penentuan peringkat provinsi dan kabupaten/kota (Kemenkes RI, 2019). Indikator pembangunan kesehatan yang diukur dalam IPKM meliputi kesehatan balita, kesehatan ibu, penyakit menular, penyakit tidak menular, kesehatan reproduksi, dan status gizi. Sementara itu, data jarak antar kabupaten/kota Provinsi Jawa Barat dan jumlah penduduk pada setiap kabupaten/kota Provinsi Jawa Barat diperoleh dari BPS.