

Metode *Subtractive Fuzzy C-Means* dalam Pengelompokan Provinsi di Indonesia Berdasarkan Keluarga Risiko *Stunting*

Fathina Nafisa Putri¹, Admi Salma^{✉2}

Departemen Statistika, Universitas Negeri Padang, Indonesia^{1,2}
email: fthnanafisaa13@gmail.com¹, admisalma1@fmipa.unp.ac.id²

Received 01 Maret 2026, Accepted 31 Maret 2026, Published 31 Maret 2026

Abstrak

Stunting merupakan permasalahan gizi kronis yang masih dihadapi Indonesia saat ini. Salah satu upaya dalam percepatan penurunan *stunting* yang dilakukan pemerintah yaitu melalui pendekatan keluarga berisiko *stunting* (KRS). Penelitian ini bertujuan untuk mengelompokkan provinsi di Indonesia berdasarkan KRS menggunakan 8 variabel penelitian diperoleh dari data KRS yang terdiri dari keluarga sasaran dan faktor risiko. Penelitian ini menggunakan metode *Subtractive Fuzzy C-Means* untuk mengelompokkan provinsi berdasarkan kepadatan data tanpa penentuan jumlah klaster di awal serta mampu menangani ketidakpastian dan tumpang tindih antar data, sehingga hasilnya diharapkan dapat menjadi rujukan bagi pemerintah dalam merancang intervensi yang tepat sasaran dan sesuai dengan karakteristik masing-masing klaster. Hasil analisis menggunakan metode *Subtractive Fuzzy C-Means* dengan jari-jari 0.5 menghasilkan 2 klaster. Klaster pertama terdiri dari 35 provinsi dengan jumlah keluarga berisiko *stunting* yang relatif rendah dibandingkan dengan klaster 2 dengan jumlah keluarga berisiko *stunting* tinggi sehingga memerlukan perhatian lebih dan menjadi prioritas dalam pelaksanaan program percepatan penurunan *stunting* melalui pendekatan keluarga berisiko *stunting*.

Kata Kunci: *Stunting*; *Subtractive Fuzzy C-Means*; Pengelompokan.

Abstract

Stunting remains a chronic nutritional problem faced by Indonesia today. One of the government's strategies to accelerate *stunting* reduction is through the families at risk of *stunting* (FRS) approach. This study aims to cluster provinces in Indonesia based on FRS using eight research variables derived from FRS data, which include target families and risk factors. This study applies the *Subtractive Fuzzy C-Means* method to cluster provinces based on data density without determining the number of clusters in advance, while also handling uncertainty and overlap between data, so that the results are expected to serve as a reference for the government in designing targeted interventions that align with the characteristics of each cluster. The results of the analysis using a radius parameter of 0.5 produced two clusters. The first cluster consists of 35 provinces with a relatively lower number of families at risk of *stunting*, while the second cluster shows a higher number and therefore requires greater attention and should become a priority in implementing programs aimed at accelerating *stunting* reduction through the families at risk of *stunting* approach.

Keywords: *Stunting*; *Subtractive Fuzzy C-Means*; Clustering

✉ Corresponding author

PENDAHULUAN

Stunting merupakan permasalahan gizi kronis yang masih dihadapi Indonesia saat ini. Berdasarkan hasil Survei Status Gizi Indonesia (SSGI) tahun 2024, prevalensi *stunting* di Indonesia tercatat sebesar 19,8%, angka ini belum mampu mencapai target 14% yang ditetapkan oleh pemerintah dalam Peraturan Presiden Nomor 72 Tahun 2021 tentang Percepatan Penurunan *Stunting* [1]. Menurut Kementerian Kesehatan Republik Indonesia (Kemenkes RI), *stunting* didefinisikan sebagai permasalahan gizi kronis yang berlangsung dalam jangka waktu cukup lama pada 1000 Hari Pertama Kehidupan (HPK), yaitu sejak pertama kali terbentuknya janin dalam kandungan, hingga anak berusia 2 tahun [2]. Masalah gizi pada periode 1000 HPK tidak hanya berdampak pada terhambatnya pertumbuhan fisik dan meningkatnya risiko anak terkena penyakit, tetapi juga dapat mengganggu perkembangan kemampuan berpikir dan belajar pada anak. Dampak jangka panjang dari *stunting* yaitu dapat menurunkan kemampuan kognitif dan prestasi pendidikan, meningkatkan risiko obesitas pada masa kanak-kanak, serta meningkatkan risiko penyakit kronis pada usia dewasa [3].

Berbagai upaya telah dilakukan pemerintah untuk mengatasi permasalahan *stunting* di Indonesia. Berdasarkan Peraturan Presiden Nomor 72 Tahun 2021, salah satu strategi yang dilakukan pemerintah yaitu pendekatan keluarga berisiko *stunting* (KRS) [4]. Dalam mendukung percepatan penurunan *stunting* melalui pendekatan KRS, dilakukan penyediaan data keluarga berisiko *stunting* yang terdiri dari keluarga sasaran dan faktor risiko. Keluarga sasaran merupakan keluarga yang menjadi sasaran dalam intervensi penurunan risiko *stunting* [5]. Keluarga sasaran meliputi keluarga yang memiliki Pasangan Usia Subur (PUS), PUS hamil, keluarga yang memiliki anak usia 0–23 bulan (baduta), serta keluarga yang memiliki anak usia 24–59 bulan (balita). Sementara itu, faktor risiko *stunting* merupakan variabel yang digunakan untuk menentukan risiko *stunting* dari suatu keluarga [5]. Faktor risiko mencakup karakteristik kondisi perumahan dan kondisi PUS, yaitu keluarga tidak memiliki sumber air minum utama yang layak, keluarga tidak memiliki jamban yang layak, PUS 4T (Terlalu muda, Terlalu tua, Terlalu dekat, dan Terlalu banyak), dan PUS 4T yang bukan peserta KB modern.

Berdasarkan publikasi data KRS tahun 2024, menunjukkan jumlah keluarga berisiko *stunting* antarprovinsi sangat bervariasi. Provinsi Jawa Barat mencatat jumlah keluarga berisiko *stunting* tertinggi yaitu 1.665.674 dan Provinsi Papua Barat mencatat jumlah KRS terendah yaitu 21.618 [6]. Tingginya variasi profil KRS antarprovinsi disebabkan oleh faktor risiko yang berbeda-beda di setiap provinsi, sehingga diperlukan metode pengelompokan yang dapat memungkinkan suatu provinsi memiliki kedekatan karakteristik lebih dari satu kelompok sekaligus dan mampu memahami faktor-faktor penyebab yang paling dominan memengaruhi jumlah KRS di setiap provinsi.

Analisis pengelompokan wilayah di Indonesia telah dilakukan menggunakan berbagai pendekatan seperti metode *K-Means Clustering* dan metode *Fuzzy C-Means Clustering*. Namun, metode *K-Means* memiliki keterbatasan dalam menangani data yang bersifat tegas (*hard clustering*) dan kedua metode ini memiliki kelemahan yaitu mengharuskan penentuan jumlah klaster di awal dan sangat sensitif terhadap pemilihan pusat klaster awal, sehingga dapat menghasilkan pengelompokan yang berbeda-beda dan kurang konsisten. Oleh karena itu, diperlukan pendekatan yang

dapat mengatasi kelemahan tersebut. Salah satu metode pengelompokan yang relevan yaitu metode *Subtractive Fuzzy C-Means*. Metode *Subtractive Fuzzy C-Means* merupakan gabungan dari kedua metode yaitu metode *Subtractive Clustering* dan *Fuzzy C-Means*. Metode ini dikembangkan untuk mengatasi kelemahan dari metode *Fuzzy C-Means* yang sensitif terhadap inisialisasi nilai awal. Kelebihan metode *Subtractive Fuzzy C-Means* yaitu dapat mempercepat laju konvergensi dan tidak perlu menentukan jumlah kluster sebelum algoritma dijalankan [7].

Tingginya variasi jumlah KRS disebabkan oleh faktor penyebab yang bervariasi di masing-masing provinsi. Metode *Subtractive Fuzzy C-Means* dapat menangani hal tersebut karena menggunakan konsep logika *fuzzy*. Pendekatan logika *fuzzy* mampu merepresentasikan ketidakpastian dan ambiguitas data melalui fungsi keanggotaan [8]. Metode ini telah digunakan pada penelitian sebelumnya oleh Nisa pada tahun 2024 untuk pengelompokan provinsi di Indonesia berdasarkan faktor penyebab *stunting* [9]. Namun hingga saat ini, belum terdapat penelitian mengenai pengelompokan provinsi di Indonesia berdasarkan Keluarga Berisiko *Stunting* menggunakan pendekatan *fuzzy clustering*.

Berdasarkan uraian tersebut, penelitian ini bertujuan untuk mengelompokkan provinsi di Indonesia berdasarkan keluarga berisiko *stunting* menggunakan metode *Subtractive Fuzzy C-Means*. Hasil pengelompokan diharapkan dapat memberikan gambaran bagi pemerintah dalam menentukan prioritas dan strategi intervensi penurunan *stunting* secara lebih tepat sasaran sesuai dengan profil dominan faktor risiko di masing-masing kelompok provinsi.

METODOLOGI

Data yang digunakan pada penelitian ini yaitu data sekunder yang diperoleh dari platform Sistem Informasi Keluarga (SIGA) <https://siga.bkkbn.go.id>, oleh Badan Kependudukan dan Keluarga Berencana Nasional (BKKBN). Data yang digunakan merupakan data Keluarga Risiko Stunting (KRS) tahun 2024 dengan jumlah observasi 38 provinsi di Indonesia. Variabel yang digunakan dalam penelitian ini adalah variabel yang disediakan oleh BKKBN dalam data KRS yang terdiri dari keluarga sasaran dan faktor risiko. Daftar variabel yang digunakan pada penelitian ini dapat dilihat pada Tabel 1.

Tabel 1. Variabel Penelitian

Variabel	Keterangan	Skala Data
X_1	Jumlah keluarga yang memiliki istri usia 15-49 tahun (PUS)	Rasio
X_2	Jumlah keluarga yang memiliki istri usia 15-49 tahun dan sedang hamil (PUS Hamil)	Rasio
X_3	Jumlah keluarga yang memiliki anak usia 0-23 bulan (baduta)	Rasio
X_4	Jumlah keluarga yang memiliki anak usia 24-59 bulan (balita)	Rasio
X_5	Jumlah keluarga tanpa sumber air minum layak	Rasio
X_6	Jumlah keluarga tanpa jamban layak	Rasio
X_7	Jumlah PUS dengan kriteria 4T (Terlalu muda, Terlalu tua, Terlalu dekat, dan Terlalu banyak)	Rasio
X_8	Jumlah PUS 4T bukan peserta KB Modern	Rasio

Analisis data pada penelitian ini menggunakan metode *Subtractive Fuzzy C-Means* yang merupakan kombinasi dari metode *Subtractive Clustering* dan metode *Fuzzy C-Means*. Metode *Subtractive Clustering* digunakan untuk inisialisasi nilai awal sebelum proses *Fuzzy C-Means* dilakukan untuk mengatasi kelemahan metode *Fuzzy C-Means* yang sensitif terhadap inisialisasi nilai awal [7]. Metode *Subtractive Clustering* bekerja berdasarkan konsep kepadatan data (*data density*), dimana setiap data dianggap sebagai kandidat pusat kluster [10]. Tingkat kepadatan suatu data dihitung berdasarkan jaraknya terhadap data lain di sekitarnya. Pada metode *Subtractive Fuzzy C-Means*, pusat kluster yang dihasilkan pada tahap *Subtractive Clustering* digunakan sebagai inisialisasi pusat kluster awal pada proses *Fuzzy C-Means*. Penelitian oleh [9], menunjukkan bahwa penggunaan *Subtractive Clustering* sebagai inisialisasi awal *Fuzzy C-Means* mampu menghasilkan solusi yang lebih optimal, mempercepat laju konvergensi, serta menghilangkan kebutuhan terhadap penentuan jumlah kluster sebelum proses pengelompokan dilakukan. Adapun tahapan yang dilakukan diuraikan sebagai berikut.

1. Menentukan nilai jari-jari (r), *Squash Factor* (SF), *Accept Ratio* (AR), *Reject Ratio* (RR), *fuzzifier* (m), batas maksimum iterasi (*MaxIter*), dan *error* (ϵ).

a. Jari-jari (r)

Jari-jari merupakan merupakan bilangan positif yang mendefinisikan area tetangga dimana data dengan banyak tetangga dalam radius tersebut akan memiliki nilai potensi tinggi untuk menjadi pusat kluster [7]. Nilai $r = 0,5$ digunakan pada penelitian sebelumnya [11], oleh karena itu pada penelitian ini digunakan $r = 0,5$.

b. *Squash Factor* (SF)

Squash factor yaitu parameter yang berfungsi untuk mengatur jarak minimal antar pusat kluster. Semakin besar nilai *squash factor*, semakin jauh jarak antar pusat kluster baru yang dihasilkan dengan pusat kluster yang sudah terbentuk sebelumnya. Nilai *squash factor* yang biasa digunakan adalah 1,25 [12]. Pada penelitian ini akan digunakan $SF = 1,25$.

c. *Accept Ratio* dan *Reject Ratio*

Accept ratio (AR) dan *reject rasio* (RR), masing-masing merupakan batas penerimaan atas dan ambang batas penolakan bawah calon pusat kluster. Nilai AR dan RR berkisar antara 0 hingga 1, dimana nilai AR harus lebih besar daripada RR [13]. Nilai AR dan RR yang umum digunakan yaitu $AR = 0,5$ dan $RR = 0,15$ [10]. Pada penelitian ini akan digunakan nilai $AR = 0,5$ dan $RR = 0,15$.

d. *Fuzzifier* (m)

Fuzzifier berperan dalam mengatur tingkat kekaburan derajat keanggotaan data terhadap kluster. Ketika nilai m mendekati 1, maka partisi yang meminimalkan fungsi objektif akan semakin bersifat tegas [14]. Nilai *fuzzifier* yang umum digunakan yaitu $m = 2$ [10]. Nilai *fuzzifier* $m = 2$ banyak digunakan pada penelitian sebelumnya [15], [16], oleh karena itu pada penelitian ini digunakan $m = 2$.

e. Maksimum Iterasi (*MaxIter*)

Maksimum iterasi merupakan batas jumlah perulangan pada algoritma *Subtractive Fuzzy C-Means*, di mana proses dihentikan ketika mencapai batas

tersebut meskipun kondisi konvergen belum terpenuhi. Pada penelitian ini, batas maksimum iterasi yang digunakan 1000 iterasi.

f. *Error* (ε)

Nilai *error* merupakan batas toleransi perubahan fungsi objektif antar iterasi, di mana proses dihentikan ketika perubahan nilai fungsi objektif dari satu iterasi ke iterasi berikutnya berada di bawah nilai *error* [14]. Pada penelitian ini digunakan $\varepsilon = 10^{-5}$.

2. Melakukan normalisasi data.

Normalisasi data bertujuan untuk menyamakan skala antar variabel. Menurut Chiu (1994), proses *clustering* dilakukan pada data yang telah dinormalisasi. Salah satu teknik normalisasi yang paling umum digunakan adalah normalisasi Min-Max, yaitu metode yang memetakan nilai data ke dalam rentang 0-1. Metode ini mempertahankan proporsi jarak relatif antar data serta memastikan bahwa seluruh atribut berada dalam rentang nilai yang sama. Untuk memperoleh nilai data hasil normalisasi Min-Max menggunakan persamaan berikut.

$$x_{ij}^* = \frac{x_{ij} - x_{minj}}{x_{maxj} - x_{minj}} \quad (1)$$

Dimana x_{minj} dan x_{maxj} masing-masing merupakan nilai minimum dan maksimum pada variabel ke- j .

3. Menghitung potensi awal setiap data untuk menjadi pusat kluster.

Potensi awal setiap data dapat dihitung menggunakan persamaan berikut.

$$P_i = \sum_l^n e^{-\frac{4\|x_{ij}-x_{lj}\|^2}{r_a^2}} \quad (2)$$

Dimana $i, l = 1, 2, \dots, n$ dan $j = 1, 2, \dots, p$. Data dengan nilai potensi tertinggi akan ditetapkan sebagai pusat kluster pertama.

$$r_b = r_a \cdot q$$

4. Selanjutnya dilakukan pembaruan potensi setiap data. Nilai potensi baru setiap data dapat dihitung menggunakan persamaan berikut.

$$P_i^* = P_i - P_k^* e^{-\frac{4\|x_{ij}-x_{kj}\|^2}{r_b^2}} \quad (3)$$

Dimana $\beta = \frac{r_b}{4}$, $r_b = r_a \times q$, P_k^* merupakan nilai potensi pusat kluster ke- k , dan x_{kj}^* merupakan nilai-nilai variabel pada pusat kluster tersebut. Setelah potensi untuk setiap data diperbarui, data dengan nilai potensi tertinggi dipilih sebagai calon pusat kluster selanjutnya. Kemudian dihitung nilai rasio antara nilai potensi tertinggi pada iterasi ke- t dengan nilai potensi tertinggi pada iterasi pertama. Nilai rasio dapat dihitung menggunakan persamaan berikut.

$$R = \frac{P_k^*}{P_1^*} \quad (4)$$

Untuk menentukan apakah calon pusat kluster yang terpilih menjadi pusat kluster selanjutnya dilakukan uji kriteria sebagai berikut [10].

- a. Jika $\frac{P_k^*}{P_1^*} > AR$, maka diterima langsung sebagai pusat kluster dan proses pembaruan pusat kluster untuk pencarian pusat kluster selanjutnya dilanjutkan.

- b. Jika $\frac{P_k^*}{P_1^*} < RR$, maka ditolak dan proses pembaruan pusat kluster dihentikan.
- c. Jika $\frac{P_k^*}{P_1^*} < AR$ dan $\frac{P_k^*}{P_1^*} > RR$, maka dilakukan perhitungan d_{min} yaitu jarak minimum antara x_k^* dengan setiap pusat kluster yang telah terbentuk sebelumnya. Selanjutnya dilakukan evaluasi,
 Jika $\frac{d_{min}}{r_a} + \frac{P_k^*}{P_1^*} \geq 1$, maka diterima sebagai pusat kluster,
 Jika $\frac{d_{min}}{r_a} + \frac{P_k^*}{P_1^*} < 1$, maka ditolak sebagai pusat kluster,
 Dan proses pembaruan pusat kluster dilanjutkan.

5. Inisialisasi matriks keanggotaan awal.

Nilai-nilai derajat keanggotaan setiap data pada setiap kluster dapat dihitung menggunakan persamaan berikut.

$$u_{ik} = \frac{\left[\sum_{j=1}^p (x_{ij} - v_{kj})^2 \right]^{-\frac{1}{m-1}}}{\sum_{k=1}^c \sum_{j=1}^p (x_{ij} - v_{kj})^{-\frac{1}{m-1}}} \quad (5)$$

Keterangan :

- c : Jumlah kluster
- p : Jumlah variabel
- m : *Fuzzifier*
- x_{ij} : Nilai variabel ke- j pada data ke- i
- v_{kj} : Nilai variabel ke- j pada pusat kluster ke- k

6. Menghitung nilai fungsi objektif awal menggunakan persamaan berikut.

$$J^t = \sum_{i=1}^n \sum_{k=1}^c \left((u_{ik})^m \left[\sum_{j=1}^p (x_{ij} - v_{kj})^2 \right] \right)$$

7. Menghitung pusat kluster.

Nilai variabel ke- j pada setiap kluster dapat dihitung menggunakan persamaan berikut.

$$v_{kj} = \frac{\sum_{i=1}^n (u_{ik})^m x_{ij}}{\sum_{i=1}^n (u_{ik})^m} \quad (6)$$

Keterangan :

- n : Jumlah data
- m : *Fuzzifier*
- u_{ik} : Nilai derajat keanggotaan data ke- i pada kluster ke- k
- x_{ij} : Nilai variabel ke- j pada data ke- i
- v_{kj} : Nilai variabel ke- j pada pusat kluster ke- k

8. Memperbarui matriks keanggotaan menggunakan persamaan (5).

9. Menghitung nilai fungsi objektif pada iterasi ke- t menggunakan persamaan (7).

10. Memeriksa konvergensi.

Algoritma dihentikan jika perubahan fungsi objektif kecil $|J^t - J^{t-1}| < \varepsilon$, atau jika iterasi telah mencapai batas maksimum iterasi $t > MaxIter$ [16]. Jika tidak memenuhi satu dari dua kondisi ini, maka proses iterasi dilanjutkan untuk $t = t + 1$.

1 dan ulangi langkah pembaruan pusat kluster sampai diperoleh kondisi konvergen.

11. Menentukan anggota kluster

Nilai derajat keanggotaan pada iterasi terakhir digunakan untuk menentukan anggota dari suatu kluster. Suatu data dapat dikatakan anggota dari suatu kluster apabila memiliki derajat keanggotaan terbesar pada kluster tersebut [17].

12. Uji Validitas

Uji validitas dilakukan validitas dirancang untuk mengukur tingkat pemisahan (*separation*) dan kekompakan (*compactness*) suatu kluster [18]. Pada penelitian ini akan digunakan metode *Silhouette Coefficient Indeks*. Metode *Silhouette* digunakan untuk mengevaluasi kualitas kluster dengan mengukur seberapa baik suatu objek berada dalam klasternya dibandingkan dengan kluster lain [19]. Perhitungan dimulai dengan menentukan nilai $a(i)$, yaitu rata-rata jarak data dengan semua data lain dalam kluster yang sama, serta nilai $b(i)$, yaitu rata-rata jarak terkecil data terhadap kluster lain. Nilai *Silhouette* setiap data dihitung dengan persamaan berikut.

$$s(i) = \frac{b(i) - a(i)}{\max \{a(i), b(i)\}} \quad (7)$$

Langkah selanjutnya adalah menghitung nilai *Silhouette Coefficient Index* (SC) menggunakan persamaan berikut.

$$SC = \frac{1}{n} \sum_{i=1}^n s(i) \quad (8)$$

Nilai SC yang mendekati 1 menunjukkan bahwa setiap data memiliki tingkat kesamaan yang tinggi terhadap anggota dalam kluster yang sama dan memiliki perbedaan jelas dengan kluster lain [19].

HASIL DAN PEMBAHASAN

Normalisasi Data

Pada penelitian ini, sebelum algoritma *Subtractive Fuzzy C-Means* dijalankan dilakukan normalisasi data. Normalisasi data dilakukan untuk menyamakan skala data. Hasil normalisasi data dapat dilihat pada Tabel 1.

Tabel 2. Normalisasi Data

Provinsi	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8
Aceh	0.0981	0.1509	0.1262	0.1172	0.0945	0.077	0.1296	0.1143
Sumatera Utara	0.2326	0.1932	0.178	0.2018	0.4051	0.2016	0.3195	0.2887
Sumatera Barat	0.0886	0.0916	0.0969	0.0996	0.1168	0.1285	0.121	0.0943
Riau	0.1239	0.0826	0.084	0.104	0.4464	0.0954	0.151	0.1399
Jambi	0.0753	0.0722	0.0687	0.0686	0.2003	0.0524	0.0783	0.0569
Sumatera Selatan	0.1704	0.1293	0.116	0.1332	0.3676	0.1254	0.1866	0.1495
Bengkulu	0.0364	0.0356	0.0375	0.0336	0.0483	0.0128	0.0374	0.0235
Lampung	0.1685	0.1148	0.1163	0.138	0.2097	0.0672	0.1717	0.1415
Kep. Bangka Belitung	0.0259	0.0268	0.0293	0.0272	0.005	0.0042	0.0279	0.0111
Kep. Riau	0.0358	0.0131	0.0233	0.0343	0.0155	0.026	0.0431	0.0478
Dki Jakarta	0.103	0.0869	0.0825	0.1161	0.001	0.0748	0.1117	0.18
Jawa Barat	1	1	1	1	0.6984	1	1	1

Jawa Tengah	0.7604	0.7495	0.7453	0.7139	0.6075	0.4379	0.7062	0.7842
DI Yogyakarta	0.0621	0.05	0.0582	0.0585	0.0556	0.0056	0.0542	0.066
Jawa Timur	0.8037	0.6804	0.6896	0.658	0.5095	0.5467	0.6963	0.7167
Banten	0.2436	0.2282	0.2117	0.2222	0.135	0.1	0.2425	0.2278
Bali	0.0745	0.0423	0.0498	0.0591	0.0569	0.0221	0.0723	0.0758
Nusa Tenggara Barat	0.1192	0.1515	0.1398	0.1351	0.0752	0.0865	0.1211	0.1215
Nusa Tenggara Timur	0.0817	0.1108	0.0896	0.1008	0.373	0.1688	0.1142	0.1335
Kalimantan Barat	0.0935	0.0522	0.0512	0.0698	1	0.1224	0.0972	0.0947
Kalimantan Tengah	0.0475	0.032	0.0323	0.0377	0.1888	0.0569	0.0461	0.0322
Kalimantan Selatan	0.0812	0.0857	0.0746	0.0723	0.1759	0.0822	0.0779	0.0595
Kalimantan Timur	0.0656	0.0329	0.043	0.058	0.049	0.0274	0.0734	0.0719
Kalimantan Utara	0.0062	0.0055	0.0085	0.0094	0.0125	0.0053	0.0075	0.0039
Sulawesi Utara	0.0362	0.0174	0.0298	0.0329	0.0261	0.035	0.0337	0.0371
Sulawesi Tengah	0.055	0.0523	0.0523	0.0553	0.0768	0.0753	0.0599	0.0576
Sulawesi Selatan	0.1541	0.1844	0.1714	0.16	0.0939	0.0521	0.1807	0.159
Sulawesi Tenggara	0.0445	0.0622	0.0628	0.0559	0.0428	0.0323	0.06	0.0493
Gorontalo	0.0196	0.0264	0.032	0.0255	0	0.0251	0.0185	0.0136
Sulawesi Barat	0.0204	0.0401	0.0389	0.0301	0.053	0.0235	0.0274	0.0225
Maluku	0.0215	0.0138	0.0139	0.0228	0.0388	0.0265	0.0297	0.0355
Maluku Utara	0.016	0.0164	0.0108	0.0146	0.0137	0.0076	0.0187	0.0155
Papua	0.0062	0.0024	0.0038	0.0076	0.0457	0.0087	0.0076	0.0147
Papua Barat	0	0.0019	0.0033	0.0038	0.0214	0	0	0
Papua Selatan	0.0012	0.0088	0.0014	0.0031	0.0456	0.0108	0.0018	0.0035
Papua Tengah	0.0054	0.0051	0.0026	0.004	0.1041	0.0353	0.0038	0.0179
Papua Pegunungan	0.0072	0.0001	0	0	0.2463	0.0697	0.0037	0.0295
Papua Barat Daya	0.0009	0	0.002	0.0039	0.02	0.0018	0.0019	0.0016

Subtractive Fuzzy C-Means

Pada penelitian ini menggunakan nilai jari-jari (r) sebesar 0.5, *Squash Factor* (SF) sebesar 1.25, *Accept Ratio* (AR) sebesar 0.5, *Reject Ratio* (RR) sebesar 0.15, *fuzzifier* (m) sebesar 2, batas maksimum iterasi (*MaxIter*) sebesar 1000, dan *error* (ϵ) sebesar 10^{-5} . Banyak kluster yang terbentuk menggunakan nilai jari-jari 0.5 sebanyak 2 kluster. Proses iterasi pada algoritma *Subtractive Fuzzy C-Means* akan terus dilakukan hingga memenuhi kondisi dimana perubahan fungsi objektif kecil $|J^t - J^{t-1}| < \epsilon$, atau jika iterasi telah mencapai batas maksimum iterasi $t > \text{MaxIter}$. Kondisi konvergen diperoleh pada iterasi ke-8. Pusat kluster pada iterasi ke-8 yang diperoleh dapat dilihat pada Tabel 3.

Tabel 3. Pusat Kluster

Kluster	X_1	X_2	X_3	X_4	X_5	X_6	X_7	X_8
Kluster 1	0.0671	0.0620	0.0599	0.0646	0.1282	0.0537	0.0755	0.0717
Kluster 2	0.8381	0.7927	0.7943	0.7736	0.6055	0.6441	0.7846	0.8175

Hasil pengelompokan provinsi di Indonesia berdasarkan KRS menggunakan nilai jari-jari 0.5 dapat dilihat pada Tabel 4.

Tabel 4. Hasil Pengelompokan

Klaster	Provinsi
Klaster 1	Aceh, Sumatera Utara, Sumatera Barat, Riau, Jambi, Sumatera Selatan, Bengkulu, Lampung, Kepulauan Bangka Belitung, Kepulauan Riau, Bali, Nusa Tenggara Barat, Nusa Tenggara Timur, Kalimantan Barat, Kalimantan Tengah, Kalimantan Selatan, Kalimantan Timur, Kalimantan Utara, Sulawesi Utara, Sulawesi Tengah, Sulawesi Selatan, Sulawesi Tenggara, Gorontalo, Sulawesi Barat, Maluku, Maluku Utara, Papua, Papua Barat, Papua Selatan, Papua Tengah, Papua Pegunungan, dan Papua Barat Daya
Klaster 2	Jawa Barat, Jawa Tengah, Jawa Timur

Berdasarkan Tabel 4, diperoleh hasil pengelompokan menggunakan metode Subtractive Fuzzy C-Means sebanyak 2 klaster. Klaster pertama terdiri dari 35 provinsi dan klaster kedua terdiri dari 3 provinsi.

Uji Vaiditas

Uji validitas yang digunakan pada penelitian ini adalah uji *Silhouette Coefficient Index* (SC). Hasil uji *Silhouette Coefficient Index* pada seluruh jari-jari dapat dilihat pada Tabel 5.

Tabel 5. Deskriptif Kelompok Berdasarkan Rata-rata

Jari-jari (r)	Jumlah Klaster	Nilai SC
0,5	2	0,8405

Berdasarkan Tabel 5, diperoleh nilai SC untuk jari-jari 0,70 dengan jumlah klaster sebanyak 2 klaster yaitu sebesar 0,8405 yang menunjukkan bahwa hasil pengelompokan memiliki kualitas sangat baik dengan pemisahan klaster yang jelas.

Karakteristik Klaster

Untuk memperoleh gambaran mengenai karakteristik setiap klaster, dilakukan dengan membandingkan nilai rata-rata umum ($\bar{X}$) setiap variabel KRS dengan nilai rata-rata variabel dari masing-masing klaster ($\bar{X}_c$ yang disajikan pada Tabel 6.

Tabel 6. Deskriptif Kelompok Berdasarkan Rata-rata

Variabel	$\bar{X}$	Klaster 1	Klaster 2
X_1	1,036,509.39	569,619	6,483,561
X_2	20,648.24	10,877	134,647
X_3	93,799.42	47,716	631,439
X_4	231,621.71	125,286	1,472,208
X_5	50,869.68	40,964	166,431
X_6	98,957.63	56,036	599,715
X_7	404,178.61	242,125	2,294,799
X_8	343,195.87	202,513	1,984,494

Selanjutnya setiap rata-rata variabel dari masing-masing klaster akan diberi tanda “+” jika nilai $\bar{X}_c \geq \bar{X}$. Sebaliknya, jika nilai $\bar{X}_c < \bar{X}$ maka akan diberi tanda negatif “-”. Apabila rata-rata variabel bernilai positif (+), artinya nilai rata-rata variabel pada

klaster tersebut berada di atas rata-rata keseluruhan. Artinya jumlah keluarga berisiko *stunting* pada variabel tersebut lebih tinggi dibandingkan rata-rata nasional. Sebaliknya, tanda negatif (–) menunjukkan nilai rata-rata klaster berada di bawah rata-rata nasional. Hasil karakteristik klaster dapat dilihat pada Tabel 5.

Tabel 6. Karakteristik Klaster		
Variabel	Klaster 1	Klaster 2
X_1	-	+
X_2	-	+
X_3	-	+
X_4	-	+
X_5	-	+
X_6	-	+
X_7	-	+
X_8	-	+

Berdasarkan Tabel 5, rata-rata seluruh variabel pada klaster 2 berada di atas rata-rata variabel secara nasional. Hal ini menunjukkan bahwa provinsi-provinsi yang termasuk dalam Klaster 2 memiliki risiko *stunting* tinggi, dimana dapat dilihat dari tingginya rata-rata jumlah keluarga berisiko *stunting* pada seluruh indikator. Sementara itu, Klaster 1 menunjukkan nilai rata-rata yang lebih rendah pada seluruh variabel, yang mengindikasikan bahwa provinsi-provinsi yang termasuk dalam Klaster 1 memiliki risiko *stunting* yang lebih rendah dibandingkan provinsi-provinsi pada Klaster 2. Dengan demikian, kebijakan pendampingan keluarga berisiko *stunting* perlu lebih difokuskan dan diprioritaskan pada provinsi-provinsi dalam Klaster 2 melalui peningkatan skala intervensi dan kapasitas layanan karena tingginya jumlah keluarga berisiko *stunting* pada klaster tersebut.

Hasil pengelompokan menggunakan metode *Subtractive Fuzzy C-Means*, diperoleh hasil pengelompokan sebanyak 2 klaster. Klaster pertama terdiri dari 35 provinsi dan klaster kedua terdiri dari 3 provinsi yaitu Jawa Barat, Jawa Tengah, dan Jawa Timur. Ketiga provinsi ini merupakan provinsi dengan populasi terbesar di Indonesia berdasarkan data dari Badan Pusat Statistik 2024. Jawa Barat memiliki jumlah penduduk lebih dari 50 juta jiwa, Jawa Timur memiliki jumlah penduduk lebih dari 41 juta jiwa, dan Jawa Tengah memiliki jumlah penduduk lebih dari 37 juta jiwa. Hal ini menunjukkan adanya hubungan antara tingginya jumlah penduduk suatu provinsi dengan tingginya jumlah keluarga berisiko *stunting*.

Meskipun demikian, hal ini bukan berarti provinsi-provinsi dalam Klaster 1 bebas dari permasalahan *stunting*. Beberapa provinsi di kawasan Indonesia Timur seperti Nusa Tenggara Timur, Papua, dan Maluku yang masuk dalam Klaster 1 diketahui memiliki prevalensi *stunting* yang tinggi secara nasional. Hal ini mengindikasikan bahwa pendekatan kebijakan untuk Klaster 1 perlu mempertimbangkan tidak hanya jumlah keluarga berisiko *stunting*, tetapi juga prevalensi dan kapasitas layanan di masing-masing daerah.

Dari sisi metodologis, penerapan metode *Subtractive Fuzzy C-Means* dalam penelitian ini memiliki keunggulan dibandingkan metode *clustering* lainnya seperti *Fuzzy C-Means* biasa, yaitu kemampuannya dalam menentukan pusat klaster awal

secara otomatis melalui konsep densitas sehingga mengurangi ketergantungan pada inisialisasi acak. Konvergensi yang dicapai pada iterasi ke-8 menunjukkan stabilitas komputasi dan efisiensi proses optimasi yang baik. Namun, penelitian ini memiliki beberapa keterbatasan. Data yang digunakan bersifat agregat tingkat provinsi sehingga tidak dapat menangkap variasi yang terjadi di tingkat Kabupaten/Kota. Selain itu, analisis juga terbatas pada satu nilai jari-jari ($r = 0.5$) sehingga sensitivitas parameter belum dievaluasi secara komprehensif. Untuk penelitian selanjutnya, disarankan untuk mengeksplorasi berbagai nilai jari-jari guna menentukan parameter optimal yang menghasilkan pengelompokan terbaik.

SIMPULAN

Penerapan metode *Subtractive Fuzzy C-Means* dalam pengelompokan provinsi di Indonesia berdasarkan indikator Keluarga Risiko Stunting (KRS) menghasilkan dua kluster. Kluster 2 terdiri atas tiga provinsi, yaitu Jawa Barat, Jawa Tengah, dan Jawa Timur, yang memiliki jumlah keluarga berisiko *stunting* lebih tinggi pada seluruh indikator dibandingkan provinsi pada Kluster 1. Hal ini menunjukkan bahwa provinsi-provinsi tersebut memerlukan perhatian dan prioritas dalam pelaksanaan program percepatan penurunan *stunting* melalui pendekatan keluarga berisiko *stunting*. Sementara itu, Kluster 1 mencakup provinsi-provinsi dengan jumlah keluarga berisiko *stunting* relatif lebih rendah. Meskipun demikian, upaya pendampingan dan intervensi keluarga tetap perlu dilakukan secara berkelanjutan untuk mencegah peningkatan risiko *stunting*.

DAFTAR PUSTAKA

- [1] Kementerian Kesehatan Republik Indonesia, "Survei Status Gizi Indonesia (SSGI) 2024," Jakarta, 2024.
- [2] Kementerian Kesehatan Republik Indonesia, "Survei Kesehatan Indonesia (SKI) 2023," Jakarta, 2023.
- [3] K. G. Dewey and K. Begum, "Long-term consequences of stunting in early life," *Matern. Child Nutr.*, vol. 7, no. SUPPL. 3, pp. 5-18, 2011, doi: 10.1111/j.1740-8709.2011.00349.x.
- [4] Indonesia, "Peraturan Presiden Republik Indonesia Nomor 72 Tahun 2021 tentang Percepatan Penurunan Stunting," 2021.
- [5] Badan Kependudukan dan Keluarga Berencana Nasional, "Modul 3 Pemutakhiran, Verifikasi dan Validasi Data Sasaran Keluarga Berisiko Stunting," Jakarta, 2022. [Online]. Available: <http://www.mercubuana.ac.id>
- [6] Badan Kependudukan dan Keluarga Berencana Nasional, "Publikasi Data Keluarga Berisiko Stunting (KRS) Tahun 2024," Jakarta, 2024.
- [7] W. Y. Liu, C. J. Xiao, B. W. Wang, Y. Shi, and S. F. Fang, "Study On Combining Subtractive Clustering With Fuzzy C-Means Clustering," *Proc. Second Int. Conf. Mach. Learn. Cybern.*, no. November, 2003.
- [8] D. S. Rahayu and M. P. Wijayanto, "Journal of science and technology," vol. 5, no. 2, pp. 165-176, 2025.
- [9] Hariati Ainun Nisa, Admi Salma, Dodi Vionanda, and Tessy Octavia Mukhti, "Impelementation of Subtractive Fuzzy C-Means Method in Clustering Provinces in Indonesia Based on Factors Causing Stunting in Toddlers," *UNP J. Stat. Data Sci.*, vol. 2, no. 2, pp. 165-172, 2024, doi: 10.24036/ujsds/vol2-iss2/164.
- [10] S. L. Chiu, "Fuzzy Model Identification Based on Cluster Estimation," *J. Intell. fuzzy Syst.*, vol. 2(3), pp. 267-278, 1994.
- [11] A. Kolus, "Application of Neuro-Fuzzy Modelling for Accurate Estimation of Oxygen

- Consumption from Heart Rate," pp. 610–621, 2023, doi: 10.46254/bd05.20220185.
- [12] N. Azizah, D. Yuniarti, and R. Goejantoro, "Penerapan Metode Fuzzy Subtractive Clustering (Studi Kasus: Pengelompokan Kecamatan di Provinsi Kalimantan Timur Berdasarkan Luas Daerah dan Jumlah Penduduk Tahun 2015)," *J. EKSPONENSIAL*, vol. 9, no. 2, pp. 197–206, 2018.
- [13] H. Sabit and A. Al-Anbuky, "Multivariate spatial condition mapping using subtractive fuzzy cluster means," *Sensors (Switzerland)*, vol. 14, no. 10, pp. 18960–18981, 2014, doi: 10.3390/s141018960.
- [14] Bezdek, J.C. (1981). *Pattern Recognition with Fuzzy Objective Function Algorithms*. New York: Plenum Press.
- [15] N. A. Fitri, M. N. Hayati, and R. Goejantoro, "Grouping Districts/Cities in Kalimantan Island Based on The People's Welfare Indicators Using Fuzzy C-Means and Subtractive Fuzzy C-Means Methods," *J. Mat. Stat. dan Komputasi*, vol. 18, no. 1, pp. 141–149, 2021, doi: 10.20956/j.v18i1.14416.
- [16] N. I. Kalla, S. Annas, and M. Fahmuddin, "Metode Subtractive Fuzzy C-Means (SFCM) dalam Pengelompokan Kabupaten/Kota di Provinsi Sulawesi Selatan Berdasarkan Indikator Kemiskinan," *VARIANSI J. Stat. Its Appl. Teach. Res.*, vol. 4, no. 2, pp. 95–108, 2022, doi: 10.35580/variensiunm25.
- [17] D. Nurmin, M. N. Hayati, R. Goejantoro, L. S. Terapan, and U. Mulawarman, "Penerapan Metode Fuzzy C-Means Pada Pengelompokan Kabupaten / Kota di Pulau Kalimantan Berdasarkan Indikator Kesejahteraan Rakyat Tahun 2020 Application of the Fuzzy C-Means Method in the Grouping of Regencies / Cities in Kalimantan Island Based on People," *J. EKSPONENSIAL*, vol. 13, pp. 189–196, 2022.
- [18] K. M. Bataineh, M. Naji, and M. Saqer, "A comparison study between various fuzzy clustering algorithms," *Jordan J. Mech. Ind. Eng.*, vol. 5, no. 4, pp. 335–343, 2011.
- [19] P. J. Rousseeuw, "Silhouettes: A graphical aid to the interpretation and validation of cluster analysis," *J. Comput. Appl. Math.*, vol. 20, no. C, pp. 53–65, 1987, doi: 10.1016/0377-0427(87)90125-7.