



Implementasi Algoritma *Artificial Bee Colony* dan *Gravitational Search* pada *Fuzzy Geographically Weighted Clustering* untuk Pemetaan *Stunting* di Sulawesi Tahun 2023

(Implementation of Artificial Bee Colony and Gravitational Search Algorithms on Fuzzy Geographically Weighted Clustering for Stunting Mapping in Sulawesi, 2023)

Djahara A. Nusi¹, Dewi Rahmawaty Isa², Salmun K. Nasib³

^{1,2,3} Program Studi Statistika, Jurusan Matematika, Fakultas Matematika dan Ilmu Pengetahuan Alam, Universitas Negeri Gorontalo, Indonesia

djaharaanusi@gmail.com¹, dewi@ung.ac.id², salmun@ung.ac.id³

Article Info

Article history:

Received: 16 Januari 2025

Revised: 11 Februari 2025

Accepted: 12 Februari 2025

Keywords:

Stunting
Fuzzy Geographically Weighted Clustering
Artificial Bee Colony
Gravitational Search Algorithm
Regional Classification

Kata Kunci:

Stunting
Fuzzy Geographically Weighted Clustering
Artificial Bee Colony
Gravitational Search Algorithm
Klasifikasi Wilayah

Abstract

Stunting is a chronic nutritional problem affecting child growth, particularly in regions with high prevalence, such as Sulawesi Island. This study aims to compare two optimization methods, Artificial Bee Colony (ABC) and Gravitational Search Algorithm (GSA), in the Fuzzy Geographically Weighted Clustering (FGWC) analysis to group regencies and cities based on factors contributing to stunting. The data used included health and socio-economic indicators from 66 regencies/cities in Sulawesi Island. Three validity indices—Classification Entropy (CE), Separation Index (SI), and Xie and Beni's Index (XB)—were employed to assess clustering performance. The findings indicate that the FGWC-ABC method outperformed FGWC-GSA, yielding lower CE and XB values and a higher SI value, signifying better clustering results. The FGWC-ABC method, at a fuzziness value of $m = 1.5$, formed two clusters: Cluster 1, comprising 49 regencies/cities with relatively lower stunting prevalence and better socio-economic conditions, and Cluster 2, consisting of 17 regencies/cities with higher stunting prevalence and poorer socio-economic conditions. This study highlights the potential of FGWC-ABC in optimizing regional classification for targeted interventions in addressing stunting. The results provide a valuable reference for policymakers in designing effective strategies to mitigate stunting issues.

Abstrak

Stunting merupakan masalah gizi kronis yang memengaruhi pertumbuhan anak, terutama di daerah dengan prevalensi tinggi seperti Pulau Sulawesi. Penelitian ini bertujuan untuk membandingkan dua metode optimasi, Artificial Bee Colony (ABC) dan Gravitational Search Algorithm (GSA), dalam analisis Fuzzy Geographically Weighted Clustering (FGWC) untuk mengelompokkan kabupaten dan kota berdasarkan faktor-faktor penyebab stunting. Data yang digunakan mencakup indikator kesehatan dan sosial ekonomi dari 66 kabupaten/kota di Pulau Sulawesi. Tiga indeks validitas—Classification Entropy (CE), Separation Index (SI), dan Xie and Beni's Index (XB)—digunakan untuk mengevaluasi kinerja klusterisasi. Hasil penelitian menunjukkan bahwa metode FGWC-ABC lebih unggul dibandingkan FGWC-GSA, dengan nilai CE dan XB yang lebih rendah serta nilai SI yang lebih tinggi, menandakan hasil klusterisasi yang lebih optimal. Metode FGWC-ABC dengan nilai fuzziness $m = 1,5$ membentuk dua klaster: Klaster 1 terdiri dari 49 kabupaten/kota dengan prevalensi stunting lebih rendah dan kondisi sosial ekonomi yang lebih baik, sedangkan Klaster 2 mencakup 17 kabupaten/kota dengan prevalensi stunting lebih tinggi dan kondisi sosial

ekonomi yang lebih buruk. Studi ini menunjukkan potensi FGWC-ABC dalam mengoptimalkan klasifikasi wilayah untuk intervensi yang lebih terarah dalam penanganan stunting. Hasil penelitian ini dapat menjadi referensi penting bagi pembuat kebijakan dalam merancang strategi yang efektif untuk mengurangi permasalahan stunting.

Corresponding Author:

Djahara A. Nusi
Fakultas Matematika dan Ilmu Pengetahuan Alam
Universitas Negeri Gorontalo
djaharaanusi@gmail.com

1. PENDAHULUAN

Secara umum, pengenalan pola adalah proses pengelompokan data ke dalam beberapa kelas atau kelompok berdasarkan parameter yang ditentukan. Terdapat dua jenis pembelajaran berbasis pengenalan pola, yaitu *supervised learning* dan *unsupervised learning*. *Supervised learning* menggunakan data berlabel, sementara *unsupervised learning* tidak menggunakan data *training*, sehingga polanya ditemukan melalui prosedur tertentu. Salah satu implementasi *unsupervised learning* adalah *Clustering* (Abbas et al., 2023).

Menurut Pourbahrami dan Azimpour (2020), *Clustering* sering dilakukan sebagai langkah pertama dalam proses data mining, dengan *Cluster* yang dihasilkan digunakan sebagai masukan lebih lanjut ke tahap yang berbeda, seperti jaringan syaraf tiruan. Karena ukuran database yang sangat besar pada saat ini maka menerapkan analisis *Clustering* pertama akan sangat-sangat membantu proses data mining. *Clustering* terbagi menjadi *hard Clustering* dan *soft Clustering*. *Hard Clustering* mengelompokkan objek berdasarkan kesamaan, sementara *soft (fuzzy) Clustering* menggunakan prinsip logika *fuzzy*, di mana suatu objek dapat menjadi milik lebih dari satu klaster pada derajat tertentu. Untuk mengatasi permasalahan *Clustering* pada data berukuran besar dan berdimensi tinggi, *fuzzy Clustering* sering digunakan (Caraka et al., 2021).

Metode *fuzzy Clustering* yang umum digunakan adalah *Fuzzy C-Means (FCM)* (Haqiqi & Kurniawan, 2015), tetapi metode ini memiliki kelemahan, seperti tidak dapat menentukan jumlah klaster dengan baik dan mudah terjebak pada solusi lokal optimum (Mashfufah et al., 2021). Untuk mengatasi hal ini, dikembangkan algoritma *Fuzzy Geographically Weighted Clustering (FGWC)*, yang lebih peka terhadap unsur geografis melalui penerapan efek populasi dan jarak. Namun, FGWC memiliki kelemahan pada proses inisialisasi, yaitu pemilihan pusat klaster awal yang acak, sehingga dapat gagal mencapai solusi global optimum (Pamungkas & Pramana, 2018).

Salah satu cara untuk mengatasi kelemahan ini adalah dengan menggunakan metode optimasi metaheuristik, yang memiliki peluang besar untuk mencapai solusi optimal secara lebih efisien. Penelitian menunjukkan bahwa optimasi FGWC dengan *Artificial Bee Colony (ABC)* dan *Gravitational Search Algorithm (GSA)* mampu memperbaiki kualitas hasil *Clustering* (Pamungkas & Pramana, 2018; Panigrahi et al., 2014). Wijayanto juga memodifikasi formula ABC untuk meningkatkan kemampuan eksploitasi algoritma ini, menggabungkan elemen dari algoritma PSO (*Particle Swarm Optimization*). Penelitian lainnya menunjukkan bahwa GSA lebih unggul dari algoritma lain dalam beberapa kasus, seperti perencanaan jalur robot di lingkungan yang tidak diketahui (Nozohour-leilabady & Fazelabdolabadi, 2016).

Dalam penelitian ini, FGWC-ABC dan FGWC-GSA akan dibandingkan untuk mengelompokkan kabupaten dan kota di Pulau Sulawesi berdasarkan faktor-faktor yang mempengaruhi *stunting* pada tahun 2023. *Stunting* adalah kondisi kurang gizi yang menyebabkan anak tumbuh lebih pendek dari usianya (Yulia et al., 2021). Faktor resiko utama terjadinya *stunting* yaitu faktor genetik, status ekonomi, jarak kelahiran, riwayat BBLR, anemia pada ibu, hygiene, sanitasi lingkungan dan defisiensi zat gizi (Satriawan, 2021; Imanni et al., 2024). Perkiraan global terbaru mengindikasikan bahwa 144 juta anak berusia <5 tahun mengalami *stunting*, 47 juta mengalami *wasting*, dan 14,3 juta mengalami gizi buruk pada tahun 2019 (Danso & Appiah, 2023). Berdasarkan Survei Status Gizi Indonesia (SSGI) dari Kementerian Kesehatan, prevalensi *stunting* pada balita di Indonesia mencapai 21,5% pada tahun 2023, dengan penurunan 2,9 poin dari tahun sebelumnya. Dari enam provinsi di Pulau Sulawesi, lima di antaranya memiliki prevalensi *stunting* di atas rata-rata nasional, kecuali Sulawesi Utara dengan prevalensi 20,5% (Satriawan, 2021).

Pengelompokan kabupaten/kota di Sulawesi berdasarkan faktor penyebab *stunting* dapat membantu pemerintah setempat merancang kebijakan yang lebih efektif untuk mengurangi angka *stunting* di wilayah

tersebut. Algoritma FGWC-ABC dan FGWC-GSA akan dibandingkan dan dievaluasi menggunakan tiga indeks validitas kluster untuk mendapatkan metode yang paling optimal dalam mendukung upaya ini.

2. METODE PENELITIAN

2.1 Pengumpulan Data

Penelitian ini merupakan penelitian eksperimental dengan pendekatan kuantitatif yang menggunakan data sekunder tentang stunting pada tahun 2023. Data diperoleh dari publikasi resmi Badan Pusat Statistik (BPS) Indonesia serta website BPS dari lima provinsi di Pulau Sulawesi. Populasi dalam penelitian ini mencakup 66 kabupaten/kota di Pulau Sulawesi, dan teknik pengambilan sampel menggunakan metode sampling jenuh, di mana seluruh populasi dijadikan sebagai sampel penelitian.

Setelah data diperoleh, langkah selanjutnya adalah melakukan standarisasi data menggunakan metode z-score. Standarisasi ini bertujuan untuk memastikan bahwa setiap variabel memiliki skala yang sama sehingga dapat dianalisis dengan lebih akurat. Dengan pendekatan ini, variabel-variabel yang memiliki satuan berbeda dapat dibandingkan secara lebih objektif dalam proses analisis clustering.

2.2 Analisis Data

Dalam penelitian ini, metode Fuzzy Geographically Weighted Clustering (FGWC) digunakan untuk melakukan pengelompokan (clustering) kabupaten/kota berdasarkan faktor-faktor yang berkontribusi terhadap stunting. Metode FGWC dipilih karena mempertimbangkan aspek geografis dan demografis dalam proses clustering, sehingga menghasilkan kelompok wilayah yang lebih representatif terhadap pola penyebaran stunting.

Selanjutnya, dua algoritma optimasi, yaitu Artificial Bee Colony (ABC) dan Gravitational Search Algorithm (GSA), diterapkan untuk meningkatkan akurasi dalam menentukan pusat cluster. Kedua algoritma ini memiliki pendekatan yang berbeda dalam proses optimasi, sehingga perbandingan keduanya diharapkan dapat menunjukkan metode yang lebih optimal dalam clustering wilayah berdasarkan indikator stunting. Analisis data dilakukan menggunakan software RStudio, yang berfungsi untuk mengolah dan membandingkan efektivitas metode FGWC dengan algoritma ABC dan GSA. Setelah hasil clustering diperoleh, pemetaan spasial dilakukan menggunakan software QGIS untuk memvisualisasikan distribusi stunting berdasarkan kelompok wilayah yang terbentuk.

Hasil clustering kemudian dievaluasi menggunakan tiga indeks validitas cluster, yaitu Partition Coefficient (PC), Classification Entropy (CE), dan Separation Index (SI). Indeks PC digunakan untuk mengukur tingkat kepastian dalam pengelompokan, CE untuk menilai tingkat ambiguitas dalam pembagian cluster, dan SI untuk mengevaluasi perbedaan antara cluster yang terbentuk. Dengan pendekatan ini, penelitian diharapkan dapat mengidentifikasi pola penyebaran stunting di Pulau Sulawesi secara lebih mendalam, sehingga dapat menjadi dasar dalam perumusan kebijakan intervensi yang lebih efektif.

3. HASIL DAN PEMBAHASAN

3.1 Statistik Deskriptif Data Penelitian

Data yang digunakan pada penelitian ini merupakan data faktor penyebab *stunting* di kabupaten dan kota di Pulau Sulawesi tahun 2023.

Tabel 1. Statistik Deskriptif Data Penelitian

Variabel	Min	Median	Mean	Max
X1	68,94	93,01	91,96	100
X2	19,46	58,10	56,55	88,33
X3	2,88	14,62	15,04	40,14
X4	35,06	48,03	56,91	57,01
X5	0,00	12,755	17,800	81,300
X6	39,42	94,12	92,00	99,84
X7	45,49	71,06	70,30	91,31
X8	45,49	71,06	70,30	91,31

Berdasarkan pada Tabel 1 dapat dilihat bahwa rentang nilai pada variabel X3 dan X5 kurang dari 20, sementara untuk nilai variabel lainnya memiliki rata-rata nilai median berkisar di atas 50. Perbedaan rentang nilai yang cukup besar dapat mempengaruhi hasil analisis data, sehingga perlu dilakukan standarisasi data terlebih dahulu sebelum melanjutkan pada tahap analisis selanjutnya.

3.2 Standarisasi Data

Pada data penelitian yang digunakan terdapat perbedaan rentang data yang cukup besar. Sehingga perlu dilakukan standarisasi data untuk mengubah data agar rentang data memiliki rata-rata nilai yang sama.

Tabel 2. Data Hasil Standarisasi

Provinsi	X1	X2	X3	...	X8
Majene	1,3419	1,254	1,0095	...	0,7154
Polewali Mandar	0,3895	0,9133	-0,4939	...	-2,7137
Mamasa	1,3330	-1,4441	-0,5211	...	-0,2055
...
Palu	-0,6586	-0,0823	-0,1576	...	-0,5622

3.3 Uji Multikolinearitas

Uji ini dilakukan untuk mendeteksi keberadaan multikolinearitas antara variabel bebas yang dilakukan dengan menghitung nilai koefisien korelasi.

Tabel 3. Hasil Pengujian Multikolinearitas

Variabel	X1	X2	X3	X4	X5	X6	X7	X8
X1	0	1,0012	1,0328	1,0025	1,0307	1,0303	1,0073	1,0073
X2	1,0012	0	1,0681	1,0005	1,0041	1,0153	1,0139	1,0139
X3	1,0328	1,0681	0	1,2145	1,0000	1,0652	1,0024	1,0024
X4	1,0025	1,0005	1,2145	0	1,0035	1,0837	1,1071	1,1071
X5	1,0307	1,0041	1,0000	1,0035	0	1,0327	1,0005	1,0005
X6	1,0303	1,0153	1,0652	1,0837	1,0327	0	1,0128	1,0128
X7	1,0073	1,0139	1,0024	1,1071	1,0005	1,0128	0	0,0000
X8	1,0073	1,0139	1,0024	1,1071	1,0005	1,0128	0,0000	0

Dari tabel tabel 3 hasil pengujian, dapat dilihat bahwa nilai V IF ≤ 10 maka H0 diterima.

3.4 Data Pembobotan Menggunakan FGWC

Pada algoritma FGWC menerapkan efek populasi dan jarak untuk setiap iterasi. Adapun populasi yang digunakan merupakan data jumlah penduduk 66 Kabupaten dan Kota di Pulau Sulawesi tahun 2023 yang terdapat pada website Badan Pusat Statistik 5 Provinsi yang ada di Sulawesi. yang disajikan pada Tabel 4.

Pembobotan Data FGWC untuk memberikan bobot pada data berdasarkan kriteria geografis dan relevansi, yang mempengaruhi bagaimana data tersebut dipertimbangkan dalam kluster dan hitung derajat keanggotaan berdasarkan bobot dan jarak data dari pusat kluster untuk mendapatkan matriks jarak yang menggambarkan kesamaan antar data. Penggunaan matriks jarak digunakan untuk mengoptimalkan posisi pusat kluster dalam FGWC, yang membantu dalam identifikasi kluster yang lebih representatif.

Tabel 4. Data Populasi

Provinsi	Jumlah Penduduk (Ribu)
Majene	181360
Polewali Mandar	495370
Mamasa	170350
...	...
Palu	387490

3.5 Matriks Jarak

Dalam klusterisasi FGWC, matriks jarak digunakan untuk membantu dalam menentukan jarak antar data dan pusat kluster untuk pembentukan kluster yang lebih akurat. Memfasilitasi pembaruan pusat kluster dengan mempertimbangkan jarak data ke pusat kluster. Memungkinkan evaluasi kesamaan atau perbedaan antar data untuk meningkatkan pemisahan kluster.

Tabel 5. Matriks Jarak

	1	2	3	...	66
1	0	1,2391	2,3633	...	75,1041
2	1,2391	0	1,2751	...	73,9595
3	2,3633	1,2751	0	...	72,7860
...
66	75,1041	73,9595	72,7860	...	0

3.6 Pembentukan Cluster Menggunakan FGWC-ABC dan FGWC-GSA

Pembentukan Cluster Kabupaten dan Kota menggunakan FGWC-ABC dan FGWC-GSA dimulai dengan menentukan parameter *Clustering* dan parameter. Adapun parameter *Clustering* yang digunakan pada penelitian ini yaitu threshold atau $\epsilon = 10^{-6}$ berdasarkan penelitian Caraka et al. (2021), selanjutnya dalam penelitian Santoso (2020) digunakan iterasi maksimum = 100, pada penelitian ini peneliti menggunakan beberapa nilai fuzziness (m) dan jumlah Cluster, yaitu m = 1, 5; m = 2; m = 2, 5 dan m = 3

dengan jumlah *Cluster* 2 sampai 9 *Cluster*. Parameter ABC yang digunakan pada penelitian ini yaitu employedbee = 10, onlookerbee = 5 dan jumlah Scout bee = 66 berdasarkan jumlah data yang digunakan yakni 66 Kabupaten dan Kota di pulau Sulawesi tahun 2023. Parameter GSA yang digunakan pada penelitian ini yaitu konstanta gravitasi awal (G) = 1, dan v_{max} = 0,7, kemudian pada penelitian ini ditetapkan jumlah agen = 66, nilai (G) = 1 menentukan kekuatan gravitasi awal yang mempengaruhi bagaimana partikel saling berinteraksi. Nilai (G) = 1 yang lebih tinggi memberikan gaya tarik yang lebih kuat pada awal iterasi, membantu eksplorasi ruang solusi. Nilai 1 sering digunakan sebagai titik awal yang umum, memberikan keseimbangan antara eksplorasi dan eksploitasi. Nilai ini membantu algoritma dalam menemukan solusi yang baik tanpa terlalu mempengaruhi dinamika awal pencarian dan untuk v_{max} mengatur batas atas kecepatan partikel dalam mencari solusi optimal. Kecepatan yang lebih tinggi memungkinkan eksplorasi yang lebih luas dan lebih cepat, sementara kecepatan yang lebih rendah meningkatkan fokus pada solusi lokal dengan nilai 0,7 adalah nilai yang sering dipilih karena memberikan kombinasi baik antara eksplorasi dan eksploitasi. Ini membantu dalam menjaga keseimbangan agar partikel tidak terlalu cepat melintasi ruang solusi tetapi tetap mampu melakukan pencarian yang efektif. Selanjutnya parameter modifikasi geografis yang digunakan berdasarkan pada penelitian Abdussamad et al. (2020), yaitu $\alpha = 0,5$, $\beta = 0,5$, $a = 1$, dan $b = 1$.

Untuk melihat kinerja ABC dan GSA dalam melakukan optimasi pusat *Cluster* awal, berikut ditampilkan perbandingan antara FGWC-ABC dengan FGWC-GSA dalam melakukan pengelompokan Kabupaten dan Kota berdasarkan faktor penyebab *stunting* yang dilakukan dengan fuzziness $m = 1,5$; $m = 2$; $m = 2,5$ dan $m = 3$ dengan jumlah *Cluster* 2 sampai 9 *Cluster*. Evaluasi kedua algoritma pengelompokan dilakukan menggunakan indeks validitas Classification Entropy (CE), Separation Index (SI), Xie and Beni's Index (XB). Dibawah ini merupakan hasil evaluasi FGWC-ABC dan FGWC-GSA yang disajikan dalam bentuk tabel.

Tabel 6. Nilai Indeks Validitas *Cluster* Classification Entropy Metode FGWC-ABC dan FGWC-GSA

m	Cluster	Classification Entropy		M	Cluster	Classification Entropy	
		FGWC-ABC	FGWC-GSA			FGWC-ABC	FGWC-GSA
1,5	2	0,6405	0,6598	2	2	0,6876	0,6928
	3	1,0363	1,0606		3	1,0985	1,0981
	4	1,3006	1,3433		4	1,3853	1,3861
	5	1,5150	1,5595		5	1,6070	1,6094
	6	1,7023	1,7391		6	1,7918	1,7917
	7	1,8288	1,9017		7	1,9458	1,9456
	8	1,9355	2,0363		8	2,0794	2,0792
	9	2,0821	2,1537		9	2,1968	2,1971
	2	0,6931	0,6931		2	0,6931	0,6931
2,5	3	1,0986	1,0986	3	3	1,0986	1,0986
	4	1,3862	1,3862		4	1,3862	1,3862
	5	1,6094	1,6094		5	1,6094	1,6094
	6	1,7917	1,7917		6	1,7917	1,7917
	7	1,9459	1,9459		7	1,9459	1,9459
	8	2,0794	2,0794		8	2,0794	2,0794
	9	2,1972	2,1972		9	2,1972	2,1972

Indeks CE terbaik diperoleh pada 2 *Cluster* dengan fuzziness 1,5, di mana FGWC-ABC menghasilkan nilai indeks CE sebesar 0,6405, menandakan kualitas *Clustering* yang terbaik.

Tabel 7. Nilai Indeks Validitas *Cluster* Separation Index Metode FGWC-ABC dan FGWC-GSA

m	Cluster	Separation Index		m	Cluster	Separation Index	
		FGWC-ABC	FGWC-GSA			FGWC-ABC	FGWC-GSA
1,5	2	3,6179	28,7579	2	2	18,6675	306,5086
	3	4,1882	22,1027		3	68565,5	2318,792
	4	45,2624	30,79296		4	5683,312	8461,262
	5	9,1977	48,1900		5	3245,71	53005,99
	6	46,4864	59,9955		6	1845903	74609,9
	7	25,2195	105,549		7	24120,49	2931,734
	8	42,5022	136,1659		8	3281094	33269,94
	9	189,3594	132,2586		9	21859,81	38034,79
	2	2,39e+15	1,52e+17		2	2,06e+17	2,31e+18

	3	2,80e+15	6,41e+16	3	1,81e+15	2,93e+18	
	4	4,28e+14	6,17e+16	4	4,50e+15	1,62e+17	
	5	3,19e+15	6,82e+16	5	1,34e+16	4,57e+17	
2,5	6	1,47e+15	2,07e+17	3	6	2,36e+15	1,15e+19
	7	1,23e+15	5,88e+16	7	1,35e+15	3,76e+17	
	8	1,32e+15	1,12e+17	8	1,48e+15	6,27e+17	
	9	1,47e+12	3,02e+16	9	3,26e+15	1,99e+17	

Nilai indeks SI terbaik diperoleh dengan 2 *Cluster* pada fuzziness 1,5, di mana FGWC-ABC menghasilkan nilai indeks SI sebesar 3,6179, menunjukkan bahwa FGWC-ABC memberikan kualitas *Clustering* terbaik pada kondisi ini.

Tabel 8. Nilai Indeks Validitas *Cluster* Xie and Beni Index Metode FGWC-ABC dan FGWC-GSA

m	Cluster	Xie and Beni Index		m	Cluster	Xie and Beni Index	
		FGWC-ABC	FGWC-GSA			FGWC-ABC	FGWC-GSA
	2	15,9374	26,8294	2	14,0435	13,6915	
	3	17,3241	18,26188	3	8,6582	8,9607	
	4	15,5774	21,0120	4	7,2528	6,5692	
	5	23,4846	16,7419	5	5,1082	5,1992	
1,5	6	20,6193	15,0595	2	6	4,2805	4,3865
	7	10,9408	10,6946	7	3,7649	3,8608	
	8	16,1272	10,2837	8	3,2364	3,3529	
	9	16,9115	9,4665	9	3,1920	2,8942	
	2	9,0272	9,0272	2	6,3832	6,3832	
	3	4,9152	4,9138	3	2,8369	2,8369	
	4	3,191613	3,191612	4	1,5958	1,5958	
	5	2,2837	2,2837	5	1,0213	1,0213	
2,5	6	1,7372	1,7372	3	6	0,7092	0,7092
	7	1,3786	1,3786	7	0,5210	0,5210	
	8	1,128406	1,128405	8	0,3989	0,3989	
	9	0,9456	0,9456	9	0,3152	0,3152	

Nilai indeks XB terbaik tercapai dengan 8 *Cluster* pada fuzziness 2,5, di mana FGWC-GSA menghasilkan indeks XB sebesar 1,128405, menunjukkan kualitas *Clustering* terbaik untuk kondisi tersebut. Berdasarkan hasil evaluasi dari tiga indeks validitas klaster (CE, SI, dan XB), Metode FGWC-ABC menghasilkan *Clustering* terbaik pada nilai fuzziness $m = 1,5$ dengan 2 *Cluster*, menurut evaluasi dari indeks validitas CE, SI, dan XB. Meskipun FGWC-ABC umumnya lebih unggul dibandingkan FGWC-GSA, kualitas *Clustering* nya menurun saat dievaluasi menggunakan indeks Xie and Beni's Index (XB).


3.7 Hasil Pembentukan *Cluster* FGWC-ABC

Tabel 9. Hasil *Clustering* Provinsi

	Cluster 1		Cluster 2
Pasangkayu	Soppeng	Banggai Laut	Majene
Mamuju Tengah	Sidenreng Rappang	Morowali Utara	Polewali Mandar
Buton	Pinrang	Palu	Mamasa
Muna	Enrekang		Mamuju
Konawe	Tana Toraja		Buton Selatan
Kolaka	Luwu Utara		Kepulauan Selayar
Konawe Selatan	Luwu Timur		Bantaeng
Bombana	Toraja Utara		Jeneponto
Wakatobi	Kota Makassar		Sinjai
Kolaka Utara	Kota Parepare		Pangkajene dan Kepulauan
Buton Utara	Boalemo		Barru
Konawe Utara	Gorontalo		Wajo
Kolaka Timur	Pohuwato		Luwu
Konawe Kepulauan	Bone Bolango		Kota Palopo
Muna Barat	Gorontalo Utara		Toli-Toli
Buton Tengah	Kota Gorontalo		Tojo Una-Una
Kendari	Banggai Kepulauan		Sigi
Bau Bau	Banggai		

	<i>Cluster 1</i>	<i>Cluster 2</i>
Bulukumba	Morowali	
Takalar	Poso	
Gowa	Donggala	
Maros	Buol	
Bone	Parigi Moutong	

Berdasarkan Tabel 9, diketahui bahwa *Cluster 1* terdiri dari 49 kabupaten dan kota, sementara *Cluster 2* terdiri dari 17 kabupaten dan kota. Dengan demikian, *Cluster 1* memiliki jumlah anggota yang lebih banyak dibandingkan *Cluster 2*. Berikut adalah pemetaan hasil *Clustering*.



Gambar 1. Pemetaan Hasil *Clustering* Provinsi

Pada Gambar 1 merupakan pemetaan hasil *Clustering* Provinsi (Tabel 9) berdasarkan faktor penyebab laju pertumbuhan penduduk, dengan Provinsi berwarna abu-abu merupakan Provinsi yang termasuk dalam *Cluster 1* dan Provinsi yang berwarna kuning tua merupakan Provinsi yang termasuk dalam *Cluster 2*.

3.8 Hasil dan Interpretasi *Cluster*

Berdasarkan penelitian Thamrin dan Wijayanto (2021), untuk menginterpretasikan karakteristik setiap *Cluster* yang terbentuk, dapat dilihat pada nilai centroid (pusat klaster) sebagai berikut.

Tabel 10. Nilai Centroid *Cluster* FGWC-ABC

Variabel	<i>Cluster</i>	
	1	2
Balita yang Mendapatkan ASI Eksklusif	-0,1077416	0,1697626
Balita yang Mendapatkan Inisiasi Menyusu Dini	-0,01729554	0,03159457
Balita dengan Berat Badan Lahir Rendah (BBLR)	0,06405228	-0,09754746
Balita yang Mendapatkan Imunisasi Dasar Lengkap	0,1794233	-0,2604149
Rumah Tangga yang Memiliki Air Minum Layak	-0,1213491	0,1825791
Rumah Tangga yang Memiliki Sanitasi Layak	0,09636206	-0,14915442
Baduta diberi MPASI	0,2286389	-0,3563059
Jaminan Kesehatan	0,2286389	-0,3563059

Cluster 1 dikelompokkan sebagai daerah dengan *stunting* rendah karena faktor-faktor positif, seperti berat badan lahir rendah (BBLR) yang rendah, imunisasi lengkap, sanitasi layak, MPASI, dan jaminan kesehatan yang tinggi. Meskipun terdapat beberapa faktor dengan nilai rendah, seperti ASI eksklusif dan inisiasi menyusu dini, faktor-faktor positif dominan memberikan kontribusi besar terhadap rendahnya prevalensi *stunting* di daerah tersebut. *Cluster 1* mencerminkan daerah di mana kombinasi faktor-faktor ini mendukung kesehatan dan pertumbuhan balita yang lebih baik, sehingga berkontribusi pada prevalensi *stunting* yang rendah.

Sebaliknya, *Cluster 2* dikelompokkan sebagai daerah dengan *stunting* tinggi karena kombinasi dari faktor-faktor negatif yang mempengaruhi kesehatan dan nutrisi balita. Di antaranya, tingginya balita dengan BBLR, rendahnya tingkat imunisasi, sanitasi yang buruk, dan jaminan kesehatan yang rendah. Selain itu, faktor-faktor tambahan seperti rendahnya ASI eksklusif, inisiasi menyusu dini, dan akses terhadap air minum layak semuanya berkontribusi pada prevalensi *stunting* yang tinggi di daerah ini. *Cluster 2* menunjukkan daerah dengan berbagai tantangan kesehatan dan nutrisi yang serius, yang memerlukan perhatian khusus dan intervensi untuk mengurangi prevalensi *stunting* dan meningkatkan kesehatan balita.

Berdasarkan interpretasi tersebut, dapat disimpulkan bahwa daerah dengan *stunting* yang tinggi berada pada *Cluster 2*. Oleh karena itu, kebijakan pemerintah harus lebih mengutamakan daerah yang berada di *Cluster 2*, terutama pada beberapa faktor dominan yang sangat mempengaruhi *stunting*.

4. KESIMPULAN DAN SARAN/REKOMENDASI

4.1 Kesimpulan

Dari hasil analisis dan pembahasan yang telah dilakukan, dapat disimpulkan bahwa kinerja metode FGWC-ABC dalam pengelompokan kabupaten dan kota di Pulau Sulawesi berdasarkan faktor-faktor yang mempengaruhi *stunting* menunjukkan hasil yang lebih baik dibandingkan dengan metode FGWC. Evaluasi menggunakan tiga indeks validitas *Cluster* yaitu Classification Entrophy (CE), Separation Index (SI), dan Xie and Beni's Index (XB), menguatkan temuan ini. Selain itu, kinerja metode FGWC GSA juga menunjukkan keunggulan dibandingkan metode FGWC, dengan hasil yang konsisten dalam hal validitas *Cluster* yang diukur.

Dari perbandingan antar pengelompokan kabupaten dan kota di Pulau Sulawesi menggunakan metode FGWC-ABC dan FGWC-GSA, metode FGWC-ABC terpilih sebagai yang terbaik. Metode ini mampu memberikan kualitas *Clustering* yang lebih optimal, menghasilkan dua *Cluster*, yaitu *Cluster 1* yang terdiri dari 49 kabupaten dan kota serta *Cluster 2* yang terdiri dari 17 kabupaten dan kota. Pada nilai fuzziness $m = 1.5$, FGWC-ABC berhasil membentuk klaster dengan lebih efisien, menegaskan efektivitas metode ini dalam analisis *stunting* di wilayah tersebut.

4.2 Saran/Rekomendasi

Pada penelitian selanjutnya dapat melakukan pengembangan pada algoritma GSA menggunakan Modified GSA, melakukan pengelompokan dengan mengintegrasikan FGWC dengan algoritma metaheuristik lainnya, serta dapat mengembangkan metode FGWC menggunakan Context Based *Clustering* dengan algoritma metaheuristik lainnya.

REFERENSI

- Abbas, K. A., Gharavi, A., Hindi, N. A., Hassan, M., Alhosin, H. Y., Gholinezhad, J., ... & Al-Saegh, S. (2023). Unsupervised machine learning technique for classifying production zones in unconventional reservoirs. *International Journal of Intelligent Networks*, 4, 29-37. doi: 10.1016/j.ijin.2022.11.007.
- Abdussamad, S. N., Astutik, S., & Effendi, A. (2020). Evaluation of Implementation Context Based Clustering In Fuzzy Geographically Weighted Clustering-Particle Swarm Optimization Algorithm. *Jurnal EECCIS (Electrics, Electronics, Communications, Controls, Informatics, Systems)*, 14(1), 10-15. doi: 10.21776/jeeccis.v14i1.609.
- Caraka, R. E., Kurniawan, R., Nasution, B. I., Jamilatuzzahro, J., Gio, P. U., Basyuni, M., & Pardamean, B. (2021). Micro, small, and medium enterprises' business vulnerability cluster in Indonesia: An analysis using optimized fuzzy geodemographic clustering. *Sustainability*, 13(14), 7807. doi: 10.3390/su13147807.
- Danso, F., & Appiah, M. A. (2023). Prevalence and associated factors influencing stunting and wasting among children of ages 1 to 5 years in Nkwanta South Municipality, Ghana. *Nutrition*, 110, 111996. doi: 10.1016/j.nut.2023.111996.
- Haqiqi, B. N., & Kurniawan, R. (2015). Analisis perbandingan metode fuzzy C-means dan subtractive fuzzy C-means. *Media Statistika*, 8(2), 59-67.
- Imanni, R. A. H., Sulistianingsih, E., & Perdana, H. (2024). CLUSTERING DISTRICT/CITY IN WEST KALIMANTAN BASED ON FACTORS CAUSING STUNTING USING K-HARMONIC MEANS METHOD. *Jurnal Statistika Universitas Muhammadiyah Semarang*, 12(1). doi: 10.14710/JSUNIMUS.12.1.2024.1.
- Mashfufah, S., Nur, I. M., & Darsyah, M. Y. (2021). Fuzzy Geographically Weighted Clustering dengan Gravitational Search Algorithm pada Kasus Penyandang Masalah Kesejahteraan Sosial di Provinsi Jawa Tengah: Fuzzy Geographically Weighted Clustering dengan Gravitational Search Algorithm pada Kasus Penyandang Masalah Kesejahteraan Sosial di Provinsi Jawa Tengah. *Jurnal Litbang Edusaintech*, 2(1), 27-36.
- Nozohour-leilabady, B., & Fazelabdolabadi, B. (2016). On the application of artificial bee colony (ABC) algorithm for optimization of well placements in fractured reservoirs; efficiency comparison with the particle swarm optimization (PSO) methodology. *Petroleum*, 2(1), 79-89. doi: 10.1016/j.petlm.2015.11.004.
- Pamungkas, I. H., & Pramana, S. (2018). Improvement method of fuzzy geographically weighted clustering using gravitational search algorithm. *Jurnal Ilmu Komputer dan Informasi*, 1, 10-16. doi: 10.21609/jiki.v1i1.580.

- Panigrahi, P. K., Ghosh, S., & Parhi, D. R. (2014). Comparison of GSA, SA and PSO based intelligent controllers for path planning of mobile robot in unknown environment. *International Journal of Electrical and Computer Engineering*, 8(10), 1633-1642.
- Pourbahrami, S., & Azimpour, S. (2020). A new method for detection of clustering based on four zones Apollonius circle. *Iran Journal of Computer Science*, 3(1), 59-64. doi: 10.1007/s42044-019-00050-1.
- Santoso, D. B. (2020). Penentuan Lokasi dan Kapasitas Wind-Based DG pada Sistem Distribusi 20 kV Menggunakan Flower Pollination Algorithm. *JTERA*, 5(1), 127-134. doi: 10.31544/jtera.v5.i1.2019.127-134.
- Satriawan, D. (2021). Pengelompokan Provinsi Di Indonesia Berdasarkan Faktor Penyebab Balita Stunting. *Buletin Penelitian Sistem Kesehatan*, 24(4), 308-317.
- Thamrin, N., & Wijayanto, A. W. (2021). Comparison of Soft and Hard Clustering: A Case Study on Welfare Level in Cities on Java Island: Analisis cluster dengan menggunakan hard clustering dan soft clustering untuk mengelompokkan tingkat kesejahteraan kabupaten/kota di pulau Jawa. *Indonesian Journal of Statistics and Its Applications*, 5(1), 141-160. doi: 10.29244/ijsa.v5i1p141-160.
- Yulia, N., Saragih, R., & Ambarita, I. (2021, June). Data Mining Pengelompokan Anak Stunting Berdasarkan Usia, Penyebab dan Pekerjaan Orang Tua Dengan Menggunakan Metode Clustering (Studi Kasus: Dinas Kesehatan Kabupaten Langkat). In *Seminar Nasional Informatika (SENATIKA)* (pp. 295-306).