

Pengelompokkan kabupaten/kota di Pulau Sulawesi berdasarkan indikator indeks khusus penanganan stunting menggunakan *Gaussian mixture model*

(Grouping of regencies/cities in Sulawesi Island based on special index indicators for handling stunting using the *Gaussian mixture model*)

Rezki Rahman*, Junaidi, Nurul Fiskia Gamayanti

Program Studi Statistika, Jurusan Matematika, Fakultas MIPA, Universitas Tadulako Palu, Sulawesi Tengah 94118, Indonesia

*korespondensi: rezkirahman086@gmail.com

Received: 18-12-2022, accepted: 16-08-2023

Abstract

Stunting or is a condition of growth failure in children under five years old (toddlers) who are malnourished. Children are called stunted if their height is below minus two standard deviations. The Special Index for Handling Stunting (IKPS) is one of the main indicators used as a measure of the achievement of handling the reduction in stunting rates. In implementing the 2024 development goals, namely setting a national stunting target that can decrease to 14%, it is necessary to identify based on the characteristics of a special index for handling stunting in each region. Method of Gaussian Mixture Model is a grouping with models that function to group a certain amount of data into a Gaussian distribution with mean and variance parameters. The main idea of model-based grouping is that object grouping is done using probabilities. This study was conducted with the aim of obtaining the results of grouping regencies/cities on Sulawesi Island based on the Special Index Indicator for Handling Stunting. The results of the study obtained different volume and shape models, coordinate axis orientation (VVI) with 4 optimum cluster. Cluster 1 with a low stunting handling index contains 24 districts/cities, cluster 2 with a medium stunting handling index contains 21 districts/cities, cluster 3 with a high stunting handling index contains 13 districts/cities, cluster 4 with a very high stunting handling index contains 23 districts/cities.

Keywords: Four optimum cluster, low, medium, high and very high

MSC2020: 62A09

1. Pendahuluan

Stunting merupakan kondisi gagal tumbuh pada anak berusia dua tahun (balita) yang menyebabkan anak menjadi kekurangan gizi yang dimulai pada awal janin tumbuh hingga anak berusia 23 bulan. Anak dikatakan mengalami gagal tumbuh (stunting) jika panjang atau tinggi badannya sekitar 8,5-11,75cm [1].

Menurut UNICEF (*United Nations Children's Fund*) dalam BAPPENAS (Badan Perencanaan Pembangunan Nasional) (2011), pada dasarnya status gizi anak dapat dipengaruhi oleh faktor langsung dan tidak langsung, faktor langsung yang berhubungan dengan stunting yaitu berat badan lahir rendah, asupan protein rendah dan infeksi ISPA dan diare. Imunisasi tidak lengkap, status ekonomi serta pola pengasuhan tidak ASI eksklusif merupakan faktor tidak langsung yang mempengaruhi stunting [2].

Penyebab stunting yaitu berkurangnya pengetahuan umum seorang ibu mengenai gizi yang baik untuk kehamilan, terbatasnya berbagai layanan kesehatan seperti pelayanan antenatal, pelayanan postnatal, rendahnya akses makanan bergizi, rendahnya akses sanitasi dan air bersih [3]. Faktor penyebab ini dapat dipengaruhi oleh pola asuh yang tidak memadai terutama dalam 1.000 Hari Pertama Kehidupan (HPK). Periode 1.000 HPK yang meliputi 270 hari selama kehamilan dan 730 hari pertama setelah bayi dilahirkan merupakan periode yang menentukan kualitas kehidupan. Apabila mengalami masalah gizi pada periode tersebut, anak akan mengalami kesulitan dalam mencapai perkembangan fisik dan kognitif yang optimal [4].

Indonesia adalah salah satu negara yang mempunyai prevalensi stunting yang cukup tinggi. Walaupun prevalensi balita stunting menunjukkan penurunan, namun prevalensi tetap tergolong tinggi [5]. Indeks Khusus Penanganan Stunting (IKPS) adalah sebagai alat ukur capaian penanganan penurunan angka stunting oleh pemerintah. Menurut BPMI, 2022, angka stunting di wilayah Pulau Sulawesi yaitu Sulawesi Utara pada tahun 2021 sebesar 21,6%, Sulawesi Tengah sebesar 29,7%, Sulawesi Selatan sebesar 20,92%, Sulawesi Tenggara sebesar 30,02%, Gorontalo sebesar 29% dan Sulawesi Barat sebesar 40,38% [6]. Saat ini, Pemerintah akan terus bergerak untuk melaksanakan pencegahan stunting dan menyusun sebuah Strategi Nasional (Stranas) Percepatan Pencegahan Anak Kerdil (Stunting) 2018-2024. Pemerintah melalui Rencana Pembangunan Jangka Menengah Nasional (RPJMN) 2020-2024, yang juga menetapkan target angka stunting nasional agar bisa turun mencapai 14% [7].

Metode *clustering* adalah suatu metode statistik yang banyak digunakan untuk mencari dan mengelompokkan data atau sejumlah objek yang dikelompokkan berdasarkan kemiripan karakteristik (*similarity*). Analisis *cluster* mengelompokkan sebuah objek yang mana setiap objek yang memiliki kesamaan dengan objek lain akan berada dalam satu kelompok yang sama, serta memiliki kemiripan satu dengan yang lain [8]. *Clustering* merupakan salah satu bagian dari ilmu data mining. Dalam analisis *cluster* ada dua jenis metode *cluster* yang sering digunakan pada pengelompokan data, yaitu *hierarchical clustering* dan *non-hierarchical clustering* [9].

Salah satu metode pengelompokan adalah menggunakan *Gaussian Mixture Model*. Algoritma *Gaussian Mixture Model* merupakan algoritma yang berfungsi mengelompokkan sejumlah data menjadi sebuah distribusi Gaussian dengan parameter *mean* (μ) dan *variance* (σ^2) [10]. Gagasan utama pengelompokan berbasis model

adalah pengelompokan objek dilakukan menggunakan peluang probabilitas, berbeda dengan metode pengelompokan lain yang menggunakan ukuran jarak sebagai penentuan *cluster*. GMM menggunakan probabilitas untuk mengidentifikasi suatu *cluster*. Probabilitas terkait dalam *mixture* yaitu setiap titik memiliki peluang untuk menjadi bagian dari suatu *cluster* [11]. GMM termasuk dalam model berbasis *clustering* atau model distribusi, parameter GMM diestimasikan menggunakan algoritma EM secara iteratif sehingga dapat terbentuk *cluster* dengan karakter yang serupa [12]. Distribusi Gaussian didefinisikan sebagai distribusi probabilitas yang mengambil kurva berbentuk lonceng. Dalam GMM, *ekspectation maximization* digunakan untuk menemukan parameter model *mixture Gaussian* Chyan [13]. Jumlah *cluster* optimal ditentukan berdasarkan pemilihan model terbaik. Pemilihan model terbaik yang umum digunakan adalah menggunakan *Bayes Information Criterion* (BIC). Model terbaik adalah yang mempunyai nilai BIC paling maksimal [14].

Sebelumnya penelitian yang telah dilakukan yang berhubungan dengan analisis GMM yaitu penelitian mengenai simulasi *clustering* provinsi Indonesia dalam penyebaran covid-19 berdasarkan Indikator Kesehatan Masyarakat dengan hasil analisis yang diperoleh 6 *cluster* optimal yaitu *cluster* yang berpotensi sangat tinggi berisi 1 provinsi, tinggi 4 provinsi, sedang 13 provinsi, cukup rendah 4 provinsi, rendah 2 provinsi, sangat rendah 10 provinsi dalam penyebaran covid-19 oleh Riyono dkk. Berdasarkan uraian yang dilampirkan maka dilakukan penelitian mengenai pengelompokan kabupaten/kota di Pulau Sulawesi berdasarkan Indikator Indeks Khusus Penanganan Stunting (IKPS) dengan menggunakan metode GMM, indikator adalah suatu ukuran tidak langsung dari suatu kejadian atau kondisi untuk melihat kabupaten/kota yang akan menjadi prioritas utama dalam penanganan penurunan angka stunting.

2. Metodologi

Langkah-langkah dalam pemodelan *mixture* yaitu sebagai berikut:

1. Menghitung nilai *mean* dan *variance*

$$\mu_c = \frac{c_1x_1 + c_2x_2 + \dots + c_nx_n}{c_1 + c_2 + \dots + c_n}, \quad (1)$$

$$\sigma_c^2 = \frac{c_1(x_1 - \mu_c)^2 + c_2(x_2 - \mu_c)^2 + \dots + c_n(x_n - \mu_c)^2}{c_1 + c_2 + \dots + c_n}.$$

2. Setelah didapatkan nilai (μ_c, σ_c^2) selanjutnya menentukan nilai probabilitas *cluster* pada data. Nilai ini menentukan *cluster* dari objek sebuah data dengan melihat nilai mana yang paling besar apakah x_i terlihat masuk di $cluster 1, 2, \dots, c_m$

$$c_i = P(c_i|x_i) = \frac{P(x_i|c_i).P(c_i)}{P(x_i)}, i = 1, 2, \dots, n,$$

dengan x_i = variabel ke- i ($i = 1, 2, \dots, n$), $P(c_i)$ = probabilitas *cluster*, μ_c = *mean cluster*, dan σ_c^2 = *variance cluster*.

Kemudian pada GMM, memiliki model dan karakteristik geometrik gaussian yaitu [15].

1. EII bentuk dan volume yang sama
2. VII volume berbeda, bentuk sama
3. EEI volume dan bentuk sama, orientasi sumbu koordinat
4. VEI volume berbeda, bentuk sama, orientasi sumbu koordinat
5. EVI volume sama, bentuk berbeda, orientasi sumbu koordinat
6. VVI volume dan bentuk berbeda, orientasi sumbu koordinat
7. EEE volume bentuk orientasi sama
8. EVE volume sama, bentuk berbeda, orientasi sama
9. VEE volume berbeda, bentuk sama, orientasi sama
10. EEV volume dan bentuk sama, orientasi berbeda
11. VEV volume berbeda, bentuk sama, orientasi berbeda
12. EVV volume sama, bentuk dan orientasi berbeda
13. VVE volume dan bentuk berbeda, orientasi sama
14. VVV volume bentuk orientasi berbeda

Data yang digunakan dalam penelitian ini adalah data sekunder yang diperoleh dari Badan Pusat Statistik (BPS) Provinsi Sulawesi Utara, Provinsi Sulawesi Tengah, Provinsi Sulawesi Selatan, Provinsi Sulawesi Tenggara, Provinsi Gorontalo dan Provinsi Sulawesi Barat tahun 2021 dengan jumlah 81 kabupaten/kota. Penentuan variabel yang digunakan mengacu pada buku publikasi IKPS 2020. Berikut merupakan variabel-variabel yang digunakan dalam penelitian.

X_1 = Imunisasi Dasar Lengkap.

X_2 = Penolong Persalinan oleh Tenaga Kesehatan di Fasilitas Kesehatan.

X_3 = Keluarga Berencana.

X_4 = ASI Eksklusif.

X_5 = Makanan Pendamping (MP) ASI.

X_6 = Air Minum Layak.

X_7 = Sanitasi Layak.

X_8 = Mengalami Kerawanan Pangan.

X_9 = Ketidakcukupan Konsumsi Pangan.

X_{10} = Pendidikan Anak Usia Dini (PAUD).

X_{11} = Pemanfaatan Jaminan Kesehatan.

X_{12} = Penerima KPS/KKS.

Analisis data dalam penelitian ini menggunakan bantuan *Software R Studio*. Tahapan-tahapan analisis yang digunakan adalah sebagai berikut:

1. Melakukan penginputan data pada aplikasi R.
2. Penentuan jumlah *cluster* optimal dengan kriteria BIC.
3. Mengelompokkan objek penelitian dengan metode GMM.
4. Memperoleh hasil *cluster* dari GMM.
5. Melakukan interpretasi hasil *clustering*.
6. Menarik kesimpulan.

3. Hasil dan Pembahasan

3.1 Penentuan Jumlah *Cluster* Optimal dengan Kriteria BIC

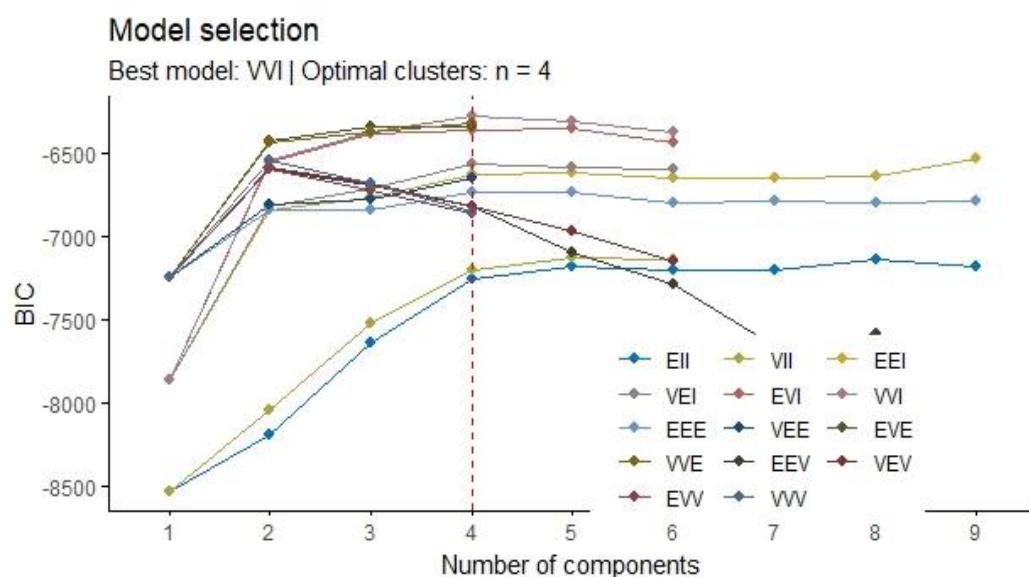
Jumlah *cluster* yang akan digunakan ditentukan berdasarkan *Bayes Information Criterion* dengan jumlah *cluster* yang paling maksimal. Hasil *output* disajikan pada Tabel 1.

Tabel 1. Nilai BIC

Model	BIC
VVI,4	-6278,888
VVI,5	-6311,535
VVE,4	-6314,977

Tabel 1 menunjukkan tiga model yang didasarkan pada nilai BIC. Penentuan jumlah *cluster* optimum ditunjukkan pada nilai BIC maksimal. Berdasarkan Tabel 1 yang telah didapatkan dari analisis diketahui nilai BIC ada pada model VVI dengan jumlah *cluster* 4. Maka pada penelitian ini dibentuk 4 *cluster*.

Selanjutnya pada bagian ini akan ditampilkan plot BIC dengan model VVI dengan jumlah *cluster* 4.



Gambar 1. Output bayes information criterion

Gambar 1 menunjukkan plot BIC dimana dapat ditarik kesimpulan bahwa model yang akan digunakan, yaitu model VVI yang disajikan dengan garis warna ungu, dengan jumlah *cluster* 4, yang di tunjukkan oleh garis vertikal putus-putus.

3.2 Gaussian Mixture Model

Pada bagian ini akan di hitung nilai *mean* (μ) dan *variance* (σ) dari tiap *cluster* pada masing-masing variabel dan menentukan nilai probabilitas, hasil *cluster* dengan bantuan *software R*.

1. Menghitung nilai *mean* (μ) dan *variance* (σ)

Berikut ini menghitung nilai *mean* (μ) dan *variance* (σ) digunakan Persamaan 1, yang bertujuan untuk mengetahui nilai parameter sebaran Gaussian. Adapun hasil disajikan pada Tabel 2.

Tabel 2. *Mean* dan *variance*

Variabel	<i>Mean</i>				<i>Variance</i>			
	<i>Cluster</i> 1	<i>Cluster</i> 2	<i>Cluster</i> 3	<i>Cluster</i> 4	<i>Cluster</i> 1	<i>Cluster</i> 2	<i>Cluster</i> 3	<i>Cluster</i> 4
X ₁	63,369	63,694	60,931	62,634	91,878	99,558	45,276	55,574
X ₂	43,753	95,323	26,747	25,261	519,148	18,289	97,641	291,898
X ₃	23,809	16,727	28,480	25,795	73,693	14,033	33,428	108,278
X ₄	72,183	75,495	11,121	72,920	112,834	56,569	7,284	46,145
X ₅	77,839	76,951	82,268	83,889	47,502	48,959	37,137	30,747
X ₆	86,716	90,084	89,136	92,647	176,449	65,735	44,667	24,032
X ₇	96,206	98,192	92,890	96,366	14,421	2,532	31,677	15,636
X ₈	0,339	0,307	60,576	0,593	0,027	0,015	4,994	0,086
X ₉	1,411	1,363	53,532	2,323	0,333	0,183	12,439	0,713
X ₁₀	34,646	21,385	39,167	25,699	101,241	79,684	119,164	252,102
X ₁₁	15,214	1,554	1,673	82,709	89,719	4,781	3,637	45,125
X ₁₂	8,212	9,100	8,543	15,209	18,727	22,496	16,539	90,569

2. Menentukan nilai probabilitas *cluster* dari setiap kabupaten/kota

Nilai probabilitas dalam suatu *cluster* dari setiap data akan dilihat berdasarkan dengan nilai probabilitas terbesar menggunakan Persamaan 2. Penentuan nilai probabilitasnya dapat dilihat dari nilai yang terdapat dalam suatu *cluster* yang telah dihasilkan dari *Software R* dan nilai yang paling besar yang terdapat pada *cluster* akan menentukan wilayah tersebut masuk ke kedalam kategori *cluster* 1, 2, 3, atau 4. Beberapa nilai probabilitas terbesar dengan hasil *output* yang disajikan pada Tabel 3.

Tabel 3. Nilai probabilitas tiap kabupaten/kota

No	Kabupaten/Kota	Cluster				Cluster
		1	2	3	4	
1	Kab. Bolaang Mongondow	$9,999 \times 10^{-01}$	$2,398 \times 10^{-101}$	0	$1,357 \times 10^{-14}$	1
2	Kab. Minahasa	$9,999 \times 10^{-01}$	$2,604 \times 10^{-34}$	0	$4,754 \times 10^{-22}$	1
3	Kab. Kepulauan Sangihe	$9,999 \times 10^{-01}$	$1,054 \times 10^{-34}$	0	$3,238 \times 10^{-20}$	1
4	Kab. Talaud	$9,999 \times 10^{-01}$	$6,706 \times 10^{-39}$	$1,435 \times 10^{-296}$	$1,488 \times 10^{-22}$	1
5	Kab. Minahasa Selatan	$9,999 \times 10^{-01}$	$5,284 \times 10^{-53}$	0	$9,124 \times 10^{-15}$	1
:	
28	Kota Palu	0	0	$9,999 \times 10^{-01}$	0	3
33	Kab. Takalar	$7,202 \times 10^{-06}$	$9,999 \times 10^{-01}$	0	$3,957 \times 10^{-40}$	2
34	Kab. Gowa	$7,880 \times 10^{-05}$	$9,999 \times 10^{-01}$	0	$1,627 \times 10^{-38}$	2
35	Kab. Sinjai	$3,683 \times 10^{-04}$	$9,996 \times 10^{-01}$	0	$1,269 \times 10^{-38}$	2
36	Kab. Maros	$3,449 \times 10^{-05}$	$9,999 \times 10^{-01}$	0	$1,139 \times 10^{-33}$	2
:	
46	Kab. Tana Toraja	$9,999 \times 10^{-01}$	$2,610 \times 10^{-07}$	0	$1,180 \times 10^{-39}$	1
47	Kab. Luwu Utara	$1,225 \times 10^{-04}$	$9,998 \times 10^{-01}$	0	$1,968 \times 10^{-38}$	2
48	Kab. Luwu Timur	$3,177 \times 10^{-03}$	$9,968 \times 10^{-01}$	0	$9,999 \times 10^{-01}$	2
49	Kab. Toraja Utara	$6,391 \times 10^{-02}$	$9,360 \times 10^{-01}$	0	$2,728 \times 10^{-39}$	2
72	Kabupaten Pohuwato	$3,123 \times 10^{-15}$	0	0	$9,999 \times 10^{-01}$	4
:	
81	Kab. Mamuju Tengah	$9,999 \times 10^{-01}$	$1,345 \times 10^{-81}$	0	$1,220 \times 10^{-21}$	1

Berdasarkan Tabel 3 diperoleh nilai probabilitas tiap kabupaten/kota untuk masuk menjadi anggota dari suatu *cluster*. Keanggotaan suatu data (kabupaten/kota) ditentukan berdasarkan nilai probabilitas terbesar. Berdasarkan nilai probabilitas tersebut didapatkan informasi mengenai kecenderungan suatu kabupaten/kota untuk menjadi bagian dari suatu *cluster*. Misalnya pada Kabupaten Bolaang Mongondow dari keempat *cluster* diatas dapat diketahui Kabupaten Bolaang Mongondow masuk ke dalam *cluster* 1 berdasarkan nilai probabilitas yang paling besar di antara *cluster* 1, 2, 3, atau 4.

3.3 Hasil *Clustering*

Tabel 4. Hasil *cluster*

<i>Cluster</i>	Kabupaten/Kota	Anggota
1	Kepulauan Sangihe, Mamasa, Polewali Mandar, Bolaang Mongondow, Majene, Bolaang Mongondow Selatan, Palopo, Mamuju, Mamuju Tengah, Minahasa Selatan, Minahasa, Bolaang Mongondow Timur, Bolaang Mongondow Utara, Kotamobagu, Pasangkayu, Talaud, Bitung, Pangkep, Siau Tagulandang Biaro, Tomohon, Minahasa Tenggara, Tana Toraja, Manado, Minahasa Utara	24
2	Toraja Utara, Luwu, Enrekang, Takalar, Pare-pare, Pinrang, Sinjai, Soppeng, Jeneponto, Maros, Luwu Utara, Bone, Kepulauan Selayar, Makassar, Luwu Timur, Gowa, Sidrap, Bantaeng, Bulukumba, Wajo, Barru	21
3	Parigi Moutong, Tojo Una-una, Buol, Tolitoli, Banggai Kepulauan, Morowali, Banggai Laut, Morowali Utara, Banggai, Donggala, Sigi, Palu, Poso	13
4	Muna Barat, Konawe Kepulauan, Buton Tengah, Muna, Konawe Selatan, Kolaka Timur, Konawe, Buton Utara, Gorontalo Utara, Buton, Gorontalo, Boalemo, Bone Bolango, Kolaka Utara, Buton Selatan, Pohuwato, Bombana, Wakatobi, Baubau, Kolaka, Kota Gorontalo, Kendari, Konawe Utara	23

Pada Tabel 4 menunjukkan nama Kabupaten/kota yang terdapat pada setiap *cluster*, dimana pada sebuah *cluster* yang telah terbentuk yang menjadi sebuah kelompok akan memiliki karakteristik, maka perlu dilakukan identifikasi untuk setiap *cluster* yang telah terbentuk. Untuk nilai rata-rata untuk setiap variabel pada kabupaten/kota, disajikan pada Tabel 5.

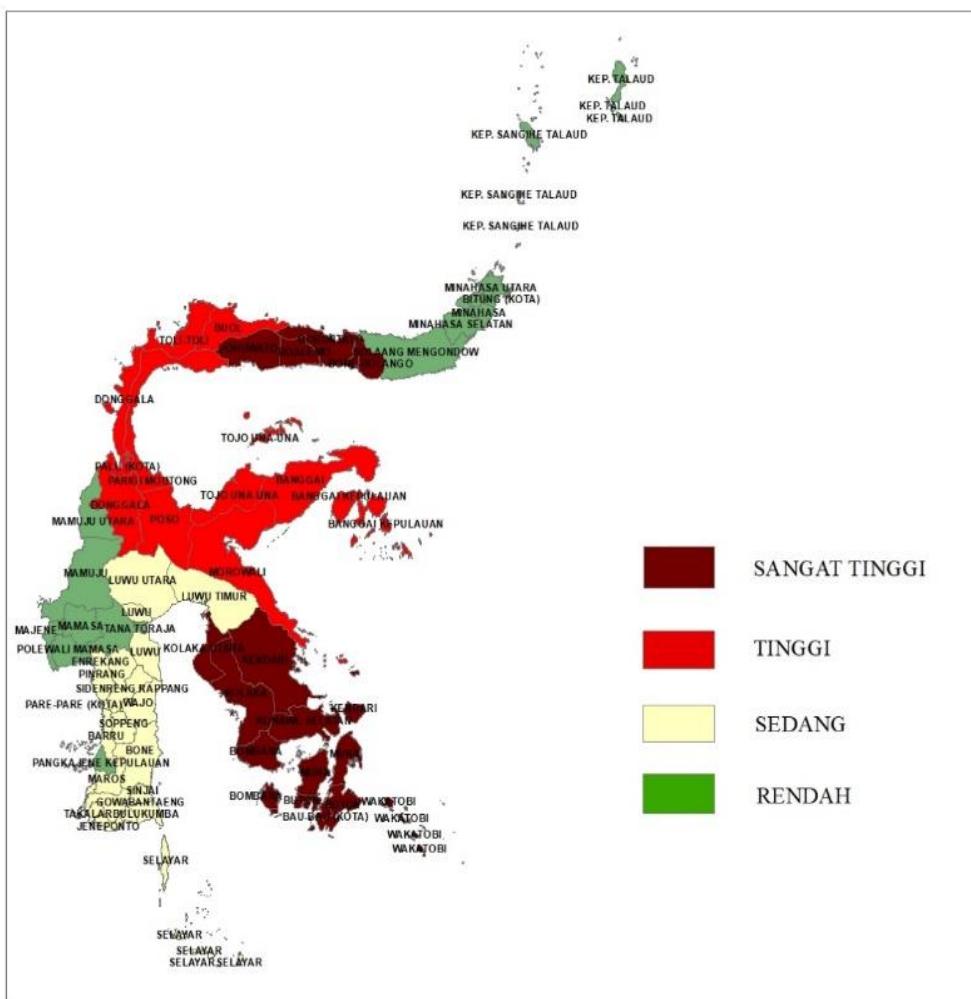
Tabel 5. Rataan *cluster*

Variabel	<i>Cluster</i> 1	<i>Cluster</i> 2	<i>Cluster</i> 3	<i>Cluster</i> 4
X ₁	63,342	63,725 * *	60,931 *	62,634
X ₂	43,676	95,319 * *	26,747	25,261 *
X ₃	23,817	16,752 *	28,480 * *	25,795
X ₄	72,202	75,459 * *	11,121 *	72,920
X ₅	77,823	76,973 *	82,268	83,889 * *
X ₆	86,756 *	90,022	89,136	92,647 * *
X ₇	96,206 *	98,183 * *	92,890	96,366
X ₈	0,339	0,307 *	60,576 * *	0,593
X ₉	1,411	1,364 *	53,532 * *	2,323
X ₁₀	34,708	21,377 *	39,167 * *	25,699
X ₁₁	15,271	1,603 *	1,881	82,709 * *
X ₁₂	8,203 *	9,106	8,543	15,209 * *

Pada Tabel 5 diperoleh hasil rata-rata masing-masing variabel pada kabupaten/kota ditandai dengan * dan **. Nilai rata-rata tinggi *cluster* ditandai dengan ** sedangkan nilai rata-rata rendah ditandai dengan *. Dari hasil yang telah didapatkan ditarik sebuah kesimpulan dengan melihat nilai rata-rata setiap *cluster* yaitu *cluster* 1 memiliki indeks penanganan stunting rendah, *cluster* 2 memiliki indeks penanganan stunting sedang, *cluster* 3 memiliki indeks penanganan stunting tinggi dan *cluster* 4 memiliki indeks penanganan stunting sangat tinggi berdasarkan IKPS.

3.4 Visualisasi Hasil *clustering* menggunakan Peta

Setelah melakukan *clusterisasi* daerah pada 81 kabupaten/kota di Pulau Sulawesi, maka dalam mempermudah mengetahui hasil *clustering* GMM dapat dilakukan visualisasi menggunakan peta Pulau Sulawesi secara langsung. Proses pemetaan bisa dilakukan menggunakan *software* ArcGIS. Adapun hasil pemetaan dari *clustering* GMM sebagai berikut.



Gambar 4. Pemetaan hasil *clustering* dengan *Gaussian Mixture Model*

Pada Gambar 4 Peta Pulau Sulawesi yang telah tercluster. Di mana pada peta tersebut, anggota *cluster* 1 diberi warna hijau, anggota *cluster* 2 diberi warna kuning, anggota *cluster* 3 diberi warna merah dan anggota *cluster* 4 diberi warna merah tua. Kondisi sangat tinggi, tinggi sedang dan rendah didasarkan pada wilayah yang dikelompokkan. Kemudian dari hasil pengelompokan tersebut dapat dilihat wilayah mana yang akan menjadi prioritas utama dalam penanggulangan penurunan angka stunting suatu wilayah.

4. Kesimpulan

Berdasarkan hasil dan pembahasan yang telah dilakukan pada penilitian ini menggunakan *Gaussian Mixture Model* dengan model “Volume dan Bentuk Berbeda, Orientasi Sumbu Koordinat (VVI)” jumlah *cluster* optimal yang terbentuk sebanyak 4 *cluster* dengan berbagai macam karakteristik yang berbeda-beda berdasarkan Indikator Indeks Khusus Penanganan Stunting. Hasil *cluster* juga divisualisasikan dalam bentuk peta Pulau Sulawesi. *Cluster* 1 terdiri dari dua puluh empat kabupaten/kota yang memiliki indeks penanganan stunting rendah berdasarkan IKPS. *Cluster* 2 terdiri dari dua puluh satu kabupaten/kota yang memiliki indeks penanganan stunting sedang berdasarkan IKPS. *Cluster* 3 terdiri dari tiga belas kabupaten/kota yang memiliki indeks penanganan stunting tinggi berdasarkan IKPS. *Cluster* 4 terdiri dari dua puluh tiga kabupaten/kota yang memiliki indeks penanganan stunting sangat tinggi berdasarkan IKPS.

Daftar Pustaka

- [1] Sukmawati, Nadimin, and A.W. Nurhayati, “Faktor yang berhubungan dengan kejadian stunting pada balita usia 24-59 bulan di Kabupaten Jeneponto,” *Media Gizi Pangan*, vol. 28, pp. 49–56, 2021.
- [2] S.M. Zian, “Faktor penyebab anak stunting usia 25-60 bulan di Kecamatan Sukorejo Kota Blitar ,” *Jurnal Ners dan Kebidanan*, vol. 5, pp. 268–278, 2018, doi: 10.26699/jnk.v5i3.ART.p268.
- [3] Y. Yuwanti, F.M. Mulyaningrum, and M.M. Susanti, “Faktor – faktor yang mempengaruhi stunting pada balita di Kabupaten Grobogan,” *J. Keperawatan dan Kesehat. Masy. Cendekia Utama*, vol. 10, no. 1, p. 74, 2021. [[GreenVersion](#)]
- [4] D. Hariyanto, W. Widada, and C.T. Hidayat, “Hubungan status sosial ekonomi keluarga dengan stunting pada balita di wilayah kerja Puskesmas Tembokrejo Kabupaten Jember,” *Keperawatan*, pp. 1–12, 2019.

- [5] A. Syahfaridzah, A.K. Panggabean, and N.A. Ardiningsih, “Mendeteksi secara otomatis objek gerakan berdasarkan *Gaussian Mixture Model* Menggunakan Aplikasi Matlab,” *METHODIKA: Jurnal Teknik Informatika dan Sistem Informasi*, vol. 6, no. 2, pp. 19–23, 2020. [[CrossRef](#)]
- [6] Kementerian Kesehatan Republik Indonesia. (2018). *Data dan Informasi Profil Kesehatan Indonesia*. Jakarta: Kementerian Kesehatan.
- [7] Biro Pers, Media dan Informasi Sekretariat Presiden. (2022). <http://stunting.go.id/tahun-2022-angka-prevalensi-stunting-harus-turun/> Fokus Penurunan Stunting. Biro Pers, Media dan Informasi Sekretariat Presiden.
- [8] E. Fammaldo and L. Hakim, “Penerapan algoritma K-means clustering untuk pengelompokan tingkat kesejahteraan keluarga untuk program Kartu Indonesia Pintar,” *J. Ilm. Teknol. Infomasi Terap.*, vol. 5, no. 1, pp. 23–31, 2019. [[CrossRef](#)]
- [9] R.T. Vulandari, “Pengelompokan tingkat keamanan wilayah Jawa Tengah berdasarkan indeks kejahatan dan jumlah pos keamanan dengan metode klastering K-means,” *J. Ilm. SINUS*, vol. Vol 14, no 2, pp. 59–72, 2016. [[CrossRef](#)]
- [10] J. Riyono, S.D. Puspa, C.E. Pujiastuti, “Simulasi *clustering* provinsi di Indonesia dalam penyebaran Covid-19 berdasarkan indikator kesehatan masyarakat menggunakan algoritma *Gaussian mixture model*” Majamath: Jurnal Matematika dan Pendidikan Matematika, vol. 5, no. 1, pp. 43–60, 2022. [[CrossRef](#)]
- [11] C. Fraley and A.E. Raftery, “Model-based clustering, discriminant analysis, and density estimation,” *Journal of the American Statistical Association.*, vol. 97, no. 458, pp. 611–631, 2002. [[CrossRef](#)]
- [12] R. Ummami and B. Winarno, “Gaussian mixture model dengan algoritme expectation maximization untuk pengelompokan data distribusi air bersih di Jawa Barat,” *Prisma Prosiding Seminar Nasional Matematika*, vol. 6, pp. 745–750, 2023,. <https://journal.unnes.ac.id/sju/index.php/prisma/>
- [13] P. Chyan, “Segmentasi kulit manusia dengan ekstraksi fitur warna dan algoritma GMM-EM,” *J. Pendidik. Teknol. Inf.*, Vol. 5, no 1, pp. 151–156, 2022. [[CrossRef](#)]
- [14] C. Fraley, A.E. Raftery, T.B. Murphy, and L. Scrucca, “MCLUST Version 4 for R: normal mixture modeling for model-based clustering, classification, and density estimation,” 2012. [[GreenVersion](#)]
- [15] L. Scrucca, M. Fop, T. B. Murphy, and A. E. Raftery, “Mcclus 5: Clustering, classification and density estimation using Gaussian finite mixture models,” *R J.*, vol. 8, no. 1, pp. 289–317, 2016. [[CrossRef](#)]