

PENGELOMPOKAN KABUPATEN/KOTA DI INDONESIA BERDASARKAN FAKTOR PENYEBAB STUNTING PADA BALITA MENGGUNAKAN ALGORITMA K-MEANS

Alia Fadilah¹, Mohammad Nurfaizy P²,

Supriyanto Lumbanbatu³, dan Sofi Defiyanti⁴

^{1,2,3,4}Teknik Informatika, Universitas Singaperbangsa Karawang

Email: alia.fadilah18167@student.unsika.ac.id¹, mohammad.nurfaizy18096@student.unsika.ac.id²,

supriyanto.lumbanbatu18092@student.unsika.ac.id³, sofi.defiyanti@unsika.ac.id⁴

Abstrak

Stunting merupakan masalah pada pertumbuhan balita yang ditandai dengan tinggi badan balita yang terlalu pendek dibanding balita seusianya. Stunting menjadi salah satu permasalahan gizi yang paling diperhatikan dunia dan permasalahan gizi yang utama di Indonesia. Indonesia termasuk dalam urutan ke-34 dari 50 negara dengan kasus balita stunting tertinggi di dunia, dan termasuk dalam urutan ke-6 di Asia Tenggara. Hasil integrasi Susenas Maret 2019 dengan Studi Status Gizi Balita Indonesia (SSGBI) tahun 2019 menunjukkan bahwa kasus balita stunting di Indonesia adalah sebesar 27.7%, angka tersebut masih belum mencapai standar yang ditetapkan WHO yaitu sebesar 20%. Oleh karena itu, diperlukan suatu metode untuk mengelompokkan Kabupaten/Kota di Indonesia berdasarkan faktor penyebab stunting pada balita, yaitu menggunakan metode clustering dengan algoritma K-Means. Tujuannya adalah untuk membantu pemerintah dalam mengambil kebijakan yang sesuai terkait penurunan prevalensi stunting pada balita berdasarkan karakteristik dan permasalahan masing-masing cluster. Hasil penelitian menunjukkan bahwa dengan bantuan metode elbow menghasilkan 2 cluster sebagai cluster terbaik dengan nilai selisih Sum of Square Error (SSE) sebesar 1401.5156, dimana cluster 1 merupakan cluster dengan faktor penyebab stunting tinggi yang terdiri dari 324 kabupaten/kota, dan cluster 2 merupakan cluster dengan faktor penyebab stunting rendah yang terdiri dari 49 kabupaten/kota.

Kata Kunci: Balita, Clustering, K-Means, SSE, Stunting

Abstract

Stunting is a problem in the growth of toddlers which is characterized by a toddler's height that is too short compared to toddlers his age. Stunting is one of the most important nutritional problems in the world and a major nutritional problem in Indonesia. Indonesia is ranked 34th out of 50 countries with the highest cases of stunting under five in the world, and is ranked 6th in Southeast Asia. The results of the integration of the March 2019 Susenas with the Study on the Nutritional Status of Indonesian Toddlers (SSGBI) in 2019 showed that the number of stunting under-fives in Indonesia was 27.7%, this figure still did not reach the WHO standard of 20%. Therefore, we need a method to classify districts/cities in Indonesia based on the factors causing stunting in children under five, namely using the clustering method with the K-Means algorithm. The aim is to assist the government in taking appropriate policies related to reducing the prevalence of stunting in children under five based on the characteristics and problems of each cluster. The results showed that with the help of the elbow method, 2 clusters were produced as the best clusters with a Sum of Square Error (SSE) difference of 1401,5156, where cluster 1 was a cluster with factors causing high stunting consisting of 324 districts/cities, and cluster 2 was a cluster with factors causing low stunting consisting of 49 districts/cities.

KeyWords : Toddler, Clustering, K-Means, SSE, Stunting.

I. PENDAHULUAN

Stunting merupakan kondisi gagalnya pertumbuhan pada balita, yang ditandai dengan keadaan tubuh balita yang terlalu pendek dibanding balita seusianya. Stunting diakibatkan karena kekurangan gizi kronis terutama dalam periode 1000 hari pertama kehidupan, yaitu sejak bayi berada dalam kandungan sampai dengan usia 23 bulan atau 2 tahun [1]. Balita yang menderita *stunting* akan lebih mudah terkena penyakit, juga berpotensi menghambat pertumbuhan fisik serta perkembangan kognitif yang akan berpengaruh terhadap tingkat kecerdasan dan produktivitas anak di masa mendatang [2].

Kekurangan darah atau anemia pada ibu hamil dapat memberikan dampak terhadap perkembangan janin yang mengakibatkan kelahiran prematur dan berat badan lahir rendah, selain itu kekurangan darah pada ibu hamil juga dapat menghambat pertumbuhan selama *postnatal* dan berisiko mengalami *stunting* [3]. Konsumsi gizi yang diperoleh balita semenjak ia lahir juga berpengaruh besar terhadap tumbuh kembangnya, tidak terlaksananya IMD yang memicu tidak tercapainya ASI secara eksklusif pada 6 bulan pertama akan mempengaruhi risiko terjadinya *stunting* [1].

Kekurangan vitamin A dapat mempengaruhi sintesis protein yang juga mempengaruhi pertumbuhan sel, dimana dengan adanya defisiensi vitamin A tersebut balita dapat berisiko mengalami penurunan imunitas dan kegagalan pertumbuhan atau *stunting* [4]. Infeksi yang berkepanjangan pada balita juga mampu mengakibatkan kejadian *stunting*, pemberian imunisasi terutama imunisasi dasar lengkap pada balita dapat membantu balita dalam mempertebal imunitasnya sehingga dapat menurunkan risiko balita dalam terserang infeksi yang dapat menimbulkan terjadinya *stunting* [5].

Penyakit tuberkulosis juga dapat mempengaruhi balita dalam masa pertumbuhannya, balita yang mengidap TBC lebih berisiko dalam mengalami *stunting*. TBC pada balita dapat mengakibatkan susah makan atau anoreksia, pada akhirnya kebutuhan nutrisi balita tidak terpenuhi. Hal ini dapat mengakibatkan malnutrisi, untuk mencegah hal ini dapat dilakukan imunisasi BCG agar dapat menurunkan risiko mengalami tuberkulosis yang berpengaruh dalam mengakibatkan terjadinya *stunting* pada balita [6].

Buruknya sanitasi juga berhubungan dengan terjadinya *stunting*, karena buruknya sanitasi akan meningkatkan risiko terjadinya penyakit infeksi, di mana penyakit infeksi semacam diare dan cacangan dapat mengganggu penyerapan konsumsi gizi pada balita, jika dibiarkan terus-menerus kondisi ini akan mengakibatkan terjadinya *stunting* [1].

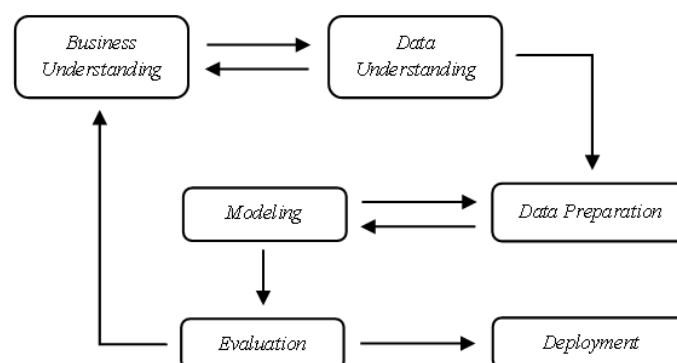
Stunting merupakan salah satu permasalahan gizi yang menjadi perhatian dunia dan merupakan masalah gizi utama yang dihadapi Indonesia [1]. Pada tahun 2019, 21.9% balita di dunia mengalami *stunting*, sebesar 33.1% kasus balita *stunting* di dunia berasal dari Afrika, 31.9% berasal dari Asia Tenggara, 24.7% berasal dari Mediterania Timur, 6.5% berasal dari Amerika, dan kasus balita *stunting* terendah yaitu sebesar 6.4% berasal dari Pasifik Barat. Indonesia termasuk dalam urutan ke-34 dari 50 negara dengan kasus balita *stunting* tertinggi di dunia, dan termasuk dalam urutan ke-6 di Asia Tenggara [7]. Hasil integrasi Susenas Maret 2019 dengan Studi Status Gizi Balita Indonesia (SSGBI) tahun 2019 menunjukkan bahwa kasus balita *stunting* di Indonesia adalah sebesar 27.7%, angka tersebut masih belum mencapai standar yang ditetapkan WHO yaitu sebesar 20%. Pemerintah dalam RPJMN menargetkan di tahun 2024 angka *stunting* bisa mengalami penurunan menjadi 14% [8].

Algoritma K-Means merupakan salah satu algoritma *clustering* yang banyak digunakan diberbagai bidang seperti bidang pendidikan, kesehatan, sosial, biologi, dan ilmu komputer [9]. Algoritma K-Means melakukan partisi data ke dalam satu atau lebih *cluster* yang memiliki ciri-ciri yang sama. Algoritma ini mampu menghasilkan akurasi atau tingkat ketelitian yang maksimal dengan sifatnya yang *linear*, waktu eksekusi algoritma ini relatif cepat dan mudah untuk diadaptasikan [10]. Terbukti pada penelitian yang dilakukan oleh Widayani & Harliana yang membandingkan algoritma K-Means dengan *Subtractive Fuzzy C-Means* (SFCM) dalam mengelompokkan data rumah tangga miskin di Kabupaten Cirebon, hasil penelitiannya menunjukkan bahwa algoritma K-Means memberikan waktu eksekusi lebih cepat dibanding SFCM, dimana K-Means memerlukan waktu 9 detik, sedangkan SFCM memerlukan waktu 13.3 detik [11]. Penelitian yang dilakukan oleh Kamila, dkk. yang membandingkan algoritma K-Means dengan K-Medoids dalam mengelompokkan data transaksi bongkar muat di Provinsi Riau, hasil penelitiannya menunjukkan bahwa algoritma K-Means memberikan waktu eksekusi lebih cepat dibanding K-Medoids, dimana K-Means memerlukan waktu rata-rata 1 detik, sedangkan K-Medoids memerlukan waktu rata-rata 1 menit 38 detik [12]. Namun algoritma K-Means memiliki beberapa kekurangan, salah satunya yaitu sensitif dalam menentukan banyaknya *cluster* [13]. Winarta & Kurniawan melakukan optimasi *cluster* dengan bantuan metode *elbow* dalam mengelompokkan data pengguna narkoba, hasil penelitiannya menunjukkan bahwa metode *elbow* bekerja sangat baik dalam membantu menghasilkan *cluster* yang optimal, dimana *cluster* yang dihasilkan adalah sebanyak 3 *cluster* dengan nilai selisih SSE sebesar 1257.862 [14].

Maka berdasarkan uraian tersebut, dalam penelitian akan dilakukan pengelompokan kabupaten/kota di Indonesia berdasarkan faktor penyebab *stunting* pada balita menggunakan algoritma k-means. Penelitian ini diharapkan dapat membantu pemerintah dalam mengambil kebijakan yang sesuai terkait penurunan prevalensi *stunting* pada balita berdasarkan karakteristik dan permasalahan masing-masing *cluster*.

II. METODE PENELITIAN

Metode penelitian yang dilakukan dalam penelitian ini menggunakan metode *Cross-Industry Standard Process for Data mining* (CRISP-DM) yang tahapannya terdiri dari 6 proses [15] seperti yang dapat dilihat pada Gambar 1 berikut.



Gambar 1: Tahapan CRISP-DM

A. Business understanding

Business understanding merupakan tahapan yang dilakukan untuk menganalisis masalah dan menentukan tujuan, kemudian mengidentifikasi strategi untuk mencapai tujuan tersebut.

B. Data understanding

Data understanding merupakan tahapapan memberikan fondasi analitik untuk sebuah penelitian dengan membuat ringkasaan (*summary*) dan mengidentifikasi potensi masalah dalam data.

C. Data preparation

Data preparation merupakan tahapan yang dilakukan setelah data dikumpulkan, dimana dalam tahap ini akan dilakukan integrasi data, lalu pembersihan data dengan mengatasi missing value yang terdapat dalam data tersebut, dan juga transformasi data.

D. Modeling

Modeling merupakan tahapan yang dilakukan untuk menentukan tools, metode, dan juga teknik data mining yang akan digunakan.

E. Evaluation

Evaluation merupakan tahapan yang dilakukan untuk mengevaluasi hasil dari pemodelan yang telah dilakukan di tahap sebelumnya.

F. Deployment

Deployment merupakan tahapan yang dilakukan untuk menyebarkan pengetahuan yang telah diperoleh ke dalam sebuah laporan hasil analisis yang lebih mudah untuk dipahami.

III. HASIL DAN PEMBAHASAN

Hasil penelitian yang telah dilakukan dengan menggunakan tahapan yang terdapat dalam metode CRISP-DM adalah sebagai berikut.

A. Business understanding

Penelitian ini bertujuan untuk melakukan pengelompokan kabupaten/kota di Indonesia berdasarkan faktor penyebab *stunting* pada balita menggunakan algoritma K-Means, dimana hasil dari pengelompokan ini akan diperoleh karakteristik faktor penyebab *stunting* pada balita di setiap *cluster*, sehingga hasil pengelompokan ini diharapkan dapat membantu pemerintah dalam mengambil kebijakan yang sesuai terkait penurunan prevalensi *stunting* pada balita berdasarkan karakteristik dan permasalahan masing-masing *cluster*.

B. Data understanding

Data dalam penelitian ini merupakan data sekunder yang diperoleh dari publikasi Dinas Kesehatan tiap Provinsi di Indonesia yang berupa data profil kesehatan tahun 2019. Adapun deskripsi dari data tersebut dapat dilihat pada Tabel I berikut.

Tabel I: Deskripsi Data

Atribut	Jenis Data
Id Provinsi	Numerik
Provinsi	Kategorik
Id Kab/Kota	Numerik
Kabupaten/Kota	Kategorik
X1 (Jumlah Ibu Hamil Penerima Tablet Tambah Darah (TTD))	Numerik
X2 (Jumlah Bayi Menerima Inisiasi Menyusui Dini (IMD))	Numerik
X3 (Jumlah Bayi Usia dibawah 6 Bulan Penerima ASI Eksklusif)	Numerik
X4 (Jumlah Bayi Menerima Vitamin A)	Numerik
X5 (Jumlah Bayi Menerima Imunisasi Dasar Lengkap)	Numerik
X6 (Jumlah Bayi Menerima Imunisasi BCG)	Numerik
X7 (Jumlah Keluarga dengan Akses Terhadap Fasilitas Sanitasi yang Layak)	Numerik

C. Data preparation

Setelah data dikumpulkan, selanjutnya data diintegrasikan, sehingga didapatkan data sebanyak 373 record yang merupakan data 23 provinsi dan 373 kabupaten/kota di Indonesia berdasarkan faktor penyebab *stunting* pada balita. Adapun tampilan dataset tersebut dapat dilihat pada Tabel II berikut.

Tabel II: Dataset

Id Provinsi	Provinsi	Id Kab/Kota	Kabupaten/Kota	X1	X2	X3	X4	X5	X6	X7
1	DKI Jakarta	1	Kabupaten Adm. Kepulauan Seribu	385	211	269	477	522	9858	385
1	DKI Jakarta	2	Kota Adm. Jakarta Barat	44667	858	23432	41628	43237	785355	44667
1	DKI Jakarta	3	Kota Adm. Jakarta Pusat	12636	6884	27848	11883	12191	205873	12636
1	DKI Jakarta	4	Kota Adm. Jakarta Selatan	36168	8024	18605	34127	34948	528740	36168
1	DKI Jakarta	5	Kota Adm. Jakarta Timur	50494	56083	17939	48214	48608	785692	50494
...
23	Kepulauan Riau	369	Kabupaten Kepulauan Anambas	757	712	188	445	791	750	4091
23	Kepulauan Riau	370	Kabupaten Lingga	1441	1157	589	1616	1181	1177	28928
23	Kepulauan Riau	371	Kabupaten Natuna	1251	1160	516	1446	1161	1260	17431
23	Kepulauan Riau	372	Kota Batam	28631	21674	16632	23892	26677	26649	340153
23	Kepulauan Riau	373	Kota Tanjung Pinang	4048	3197	1369	3545	3742	3780	64588

Langkah selanjutnya adalah melakukan pengecekan missing value seperti yang dapat dilihat pada Gambar 2 berikut.

```
> summary(is.na(df1))
  prov_id      prov_nama      kabkot_id      kabkot_nama
Mode :logical Mode :logical Mode :logical Mode :logical
FALSE:373    FALSE:373    FALSE:373    FALSE:373

      X1      X2      X3      X4
Mode :logical Mode :logical Mode :logical Mode :logical
FALSE:369    FALSE:361    FALSE:362    FALSE:371
TRUE :4      TRUE :12     TRUE :11     TRUE :2

      X5      X6      X7
Mode :logical Mode :logical Mode :logical
FALSE:373    FALSE:371    FALSE:370
TRUE :2      TRUE :2      TRUE :3
```

Gambar 2: Pengecekan Missing Value

Kemudian data yang terdapat *missing value* tersebut diisi dengan nilai *mean* agar poin data untuk melatih model tidak turun dan dapat mengurangi kinerja model, seperti yang dapat dilihat pada Gambar 3 berikut.

```
# Mengganti NA menjadi nilai mean
df1$X1=ifelse(is.na(df1$X1), mean(df1$X1, na.rm=TRUE), df1$X1)
df1$X2=ifelse(is.na(df1$X2), mean(df1$X2, na.rm=TRUE), df1$X2)
df1$X3=ifelse(is.na(df1$X3), mean(df1$X3, na.rm=TRUE), df1$X3)
df1$X4=ifelse(is.na(df1$X4), mean(df1$X4, na.rm=TRUE), df1$X4)
df1$X6=ifelse(is.na(df1$X6), mean(df1$X6, na.rm=TRUE), df1$X6)
df1$X7=ifelse(is.na(df1$X7), mean(df1$X7, na.rm=TRUE), df1$X7)
```

Gambar 3: Penanganan Missing Value dengan Nilai Mean

```
> summary(is.na(df1))
  prov_id      prov_nama      kabkot_id      kabkot_nama
Mode :logical Mode :logical Mode :logical Mode :logical
FALSE:373    FALSE:373    FALSE:373    FALSE:373

      X1      X2      X3      X4
Mode :logical Mode :logical Mode :logical Mode :logical
FALSE:373    FALSE:373    FALSE:373    FALSE:373

      X5      X6      X7
Mode :logical Mode :logical Mode :logical
FALSE:373    FALSE:373    FALSE:373
```

Gambar 4: Setelah dilakukan Penanganan Missing Value


Setelah *missing value* pada dataset tersebut berhasil ditangani seperti pada Gambar 4, selanjutnya dilakukan transformasi data yaitu menstandarisasi nilai data dengan cara diskalakan menggunakan fungsi *scale*. Adapun hasil dari transformasi data tersebut dapat dilihat pada Tabel III berikut.

Tabel III: Hasil Trasnformasi Data

Id Provinsi	Provinsi	Id Kab /Kota	Kabupaten/Kota	X1	X2	X3	X4	X5	X6	X7
1	DKI Jakarta	1	Kabupaten Adm. Kepulauan Seribu	-0,77790	-0,70864	-0,75118	-0,76377	-0,81570	-0,74092	-0,75210
1	DKI Jakarta	2	Kota Adm. Jakarta Barat	2,78123	3,12675	-0,65589	1,23028	2,77289	2,58480	3,12407
1	DKI Jakarta	3	Kota Adm. Jakarta Pusat	0,17938	0,35245	0,23157	1,61045	0,17896	0,16761	0,22764
1	DKI Jakarta	4	Kota Adm. Jakarta Selatan	2,14567	2,39063	0,39946	0,81474	2,11876	1,93944	1,84143
1	DKI Jakarta	5	Kota Adm. Jakarta Timur	3,23293	3,63144	7,47719	0,75740	3,34722	3,00298	3,12575
...
23	Kepulauan Riau	369	Kabupaten Kepulauan Anambas	-0,75111	-0,68032	-0,75456	-0,74862	-0,78832	-0,72317	-0,78093
23	Kepulauan Riau	370	Kabupaten Lingga	-0,70033	-0,64178	-0,69551	-0,64781	-0,75431	-0,68992	-0,65678
23	Kepulauan Riau	371	Kabupaten Natuna	-0,71444	-0,64152	-0,70626	-0,66244	-0,75605	-0,68346	-0,71425
23	Kepulauan Riau	372	Kota Batam	1,31800	1,13526	1,66717	1,26989	1,46908	1,29329	0,89881
23	Kepulauan Riau	373	Kota Tanjung Pinang	-0,50681	-0,46509	-0,58063	-0,48174	-0,53097	-0,48725	-0,47854

D. Modeling

Pada penelitian ini tools yang digunakan adalah RStudio, lalu metode yang digunakan adalah metode clustering dengan algoritma K-Means. Namun sebelum melakukan pemodelan, akan dilakukan metode elbow terlebih dahulu untuk menentukan jumlah cluster terbaik. Hasil dari metode elbow tersebut dapat dilihat pada Gambar 5 berikut.



Gambar 5: Penentuan Jumlah Cluster dengan Metode Elbow

Berdasarkan hasil metode *elbow* pada Gambar 5, dapat disimpulkan bahwa jumlah *cluster* terbaik pada dataset penelitian ini yaitu sebanyak 2 *cluster*. Setelah didapatkan jumlah *cluster* terbaik, maka langkah selanjutnya adalah melakukan pengelompokan data, yaitu dengan menggunakan algoritma K-Means, dan didapatkan hasil pengelompokan seperti pada Gambar 6 berikut.



Gambar 6: Plotting Cluster

Berdasarkan hasil K-Means pada Gambar 6, dapat diketahui bahwa terdapat 2 cluster pada pengelompokan kabupaten/kota berdasarkan faktor penyebab *stunting* pada balita, dimana cluster 1 terdiri dari 324 kabupaten/kota, dan cluster 2 terdiri dari 49 kabupaten/kota.

E. Evaluation

Kualitas cluster yang dihasilkan algoritma K-Means dalam mengelompokkan kabupaten/kota di Indonesia berdasarkan faktor penyebab *stunting* pada balita dengan bantuan metode elbow menghasilkan nilai *Sum of Square Error* (SSE) seperti yang dapat dilihat pada Tabel IV berikut.

Tabel IV: Evaluasi Hasil Cluster dengan Nilai SSE

Banyak Cluster	Nilai SSE	Selisih SSE
1	2604.0000	0
2	1202.4844	1401.5156
3	821.5521	380.9323
4	642.9633	178.5888
5	549.2140	93.7493
6	509.0354	40.1786
7	450.6637	58.3717
8	429.7507	20.913
9	394.9438	34.8069
10	385.9610	8.9828

Berdasarkan Tabel IV dapat diketahui bahwa kualitas cluster yang dihasilkan algoritma K-Means dalam mengelompokkan kabupaten/kota di Indonesia berdasarkan faktor penyebab *stunting* pada balita dengan bantuan metode *elbow* memperoleh nilai selisih SSE tertinggi berada pada cluster 2 yaitu sebesar 1401.5156, hal tersebut menunjukkan bahwa cluster 2 merupakan jumlah cluster yang ideal atau terbaik.

F. Deployment

Setelah cluster terbentuk langkah selanjutnya adalah memberikan ciri khusus untuk menjelaskan karakteristik dari cluster tersebut, seperti yang dapat dilihat pada Gambar 7 berikut.

```

cluster means:
      x1      x2      x3      x4      x5      x6      x7
1 -0.3041193 -0.2870892 -0.2769949 -0.2689422 -0.3063892 -0.2926462 -0.2544995
2  2.0109113  1.8983039  1.8315584  1.7783117  2.0259203  1.9350481  1.6828132
    
```

Gambar 7: Pusat Cluster Akhir

Berdasarkan hasil pada Gambar 7, dapat diketahui karakteristik dari masing-masing cluster, dimana cluster 1 yang terdiri dari 324 kabupaten/kota memiliki karakteristik dengan tingkat ibu hamil penerima tablet tambah darah, inisiasi menyusui dini, asi eksklusif, vitamin A, imunisasi dasar lengkap, imunisasi BCG, dan sanitasi yang rendah. Hal tersebut disebabkan karena keseluruhan atribut yang terdapat pada cluster 1 bernilai negatif, sehingga berdasarkan karakteristik tersebut, kabupaten/kota yang berada pada cluster 1 tergolong dalam cluster dengan faktor penyebab stunting tinggi. Lalu cluster 2 yang terdiri dari 49 kabupaten/kota memiliki karakteristik dengan tingkat ibu hamil penerima tablet tambah darah, inisiasi menyusui dini, asi eksklusif, vitamin A, imunisasi dasar lengkap, imunisasi BCG, dan sanitasi yang tinggi. Hal tersebut disebabkan karena keseluruhan atribut yang terdapat pada cluster 2 bernilai positif, sehingga berdasarkan karakteristik tersebut, kabupaten/kota yang berada pada cluster 2 tergolong dalam cluster dengan faktor penyebab stunting rendah. Adapun anggota dari cluster-cluster tersebut dapat dilihat pada Tabel V berikut.

Tabel V: Anggota Cluster

Cluster 1 (Tinggi)	
DKI Jakarta	Kabupaten Adm. Kepulauan Seribu, Kota Adm. Jakarta Pusat Jawa Barat Kabupaten Ciamis, Kabupaten Kuningan, Kabupaten Pangandaran, Kabupaten Purwakarta, Kabupaten Sumedang, Kota Banjar, Kota Bogor, Kota Cimahi, Kota Cirebon, Kota Sukabumi, Kota Tasikmalaya
Jawa Tengah	Kabupaten Banjarnegara, Kabupaten Batang, Kabupaten Blora, Kabupaten Boyolali, Kabupaten Demak, Kabupaten Grobogan, Kabupaten Jepara, Kabupaten Karanganyar, Kabupaten Kendal, Kabupaten Klaten, Kabupaten Kudus, Kabupaten Magelang, Kabupaten Pati, Kabupaten Pekalongan, Kabupaten Purbalingga, Kabupaten Purworejo, Kabupaten Rembang, Kabupaten Semarang, Kabupaten Sragen, Kabupaten Sukoharjo, Kabupaten Temanggung, Kabupaten Wonogiri, Kabupaten Wonosobo, Kota Magelang, Kota Pekalongan, Kota Salatiga, Kota Surakarta (Solo), Kota Tegal
DIY	Kabupaten Bantul, Kabupaten Gunung Kidul, Kabupaten Kulon Progo, Kabupaten Sleman, Kota Yogyakarta
Jawa Timur	Kabupaten Bangkalan, Kabupaten Blitar, Kabupaten Bojonegoro, Kabupaten Bondowoso, Kabupaten Lamongan, Kabupaten Lumajang, Kabupaten Madiun, Kabupaten Magetan, Kabupaten Mojokerto, Kabupaten Nganjuk, Kabupaten Ngawi, Kabupaten Pacitan, Kabupaten Pamekasan, Kabupaten Ponorogo, Kabupaten Probolinggo, Kabupaten Sampang, Kabupaten Situbondo, Kabupaten Sumenep, Kabupaten Trenggalek, Kabupaten Tuban, Kabupaten Tulungagung, Kota Batu, Kota Blitar, Kota Kediri, Kota Madiun, Kota Malang, Kota Mojokerto, Kota Pasuruan, Kota Probolinggo
Banten	Kabupaten Pandeglang, Kota Serang, Kota Tangerang, Kalimantan Barat, Kabupaten Bengkayang, Kabupaten Kapuas Hulu, Kabupaten Kayong Utara, Kabupaten Ketapang, Kabupaten Kubu Raya, Kabupaten Landak, Kabupaten Melawi, Kabupaten Mempawah, Kabupaten Sambas, Kabupaten Sanggau, Kabupaten Sekadau, Kabupaten Sintang, Kota Pontianak, Kota Singkawang
Kalimantan Tengah	Kabupaten Barito Selatan, Kabupaten Barito Timur, Kabupaten Barito Utara, Kabupaten Gunung Mas, Kabupaten Kapuas, Kabupaten Katingan, Kabupaten Kotawaringin Barat, Kabupaten Kotawaringin Timur, Kabupaten Lamandau, Kabupaten Murung Raya, Kabupaten Pulang Pisau, Kabupaten Seruyan, Kabupaten Sukamara, Kota Palangka Raya Kalimantan Selatan, Kabupaten Balangan, Kabupaten Banjar, Kabupaten Barito Kuala, Kabupaten Hulu Sungai Selatan, Kabupaten Hulu Sungai Tengah, Kabupaten Hulu Sungai Utara, Kabupaten Kotabaru, Kabupaten Tabalong, Kabupaten Tanah Bumbu, Kabupaten Tanah Laut, Kabupaten Tapin, Kota Banjarbaru, Kota Banjarmasin
Kalimantan Timur	Kabupaten Berau, Kabupaten Kutai Barat, Kabupaten Kutai Kartanegara, Kabupaten Kutai Timur, Kabupaten Mahakam Ulu, Kabupaten Paser, Kabupaten Penajam Paser Utara, Kota Balikpapan, Kota Bontang, Kota Samarinda
Bali	Kabupaten Badung, Kabupaten Bangli, Kabupaten Buleleng, Kabupaten Gianyar, Kabupaten Jembrana, Kabupaten Karangasem, Kabupaten Klungkung, Kabupaten Tabanan, Kota Denpasar
Nusa Tenggara Barat	Kabupaten Bima, Kabupaten Dompu, Kabupaten Lombok Barat, Kabupaten Lombok Utara, Kabupaten Sumbawa, Kabupaten Sumbawa Barat, Kota Bima, Kota Mataram
Papua	Kabupaten Asmat, Kabupaten Biak Numfor, Kabupaten Boven Digoel, Kabupaten Deiyai (Deliyai), Kabupaten Dogiyai, Kabupaten Intan Jaya, Kabupaten Jayapura, Kabupaten Jayawijaya, Kabupaten Keerom, Kabupaten Kepulauan Yapen (Yapen Waropen), Kabupaten Lanny Jaya, Kabupaten Mamberamo Raya, Kabupaten Mamberamo Tengah, Kabupaten Mappi, Kabupaten Merauke, Kabupaten Mimika, Kabupaten Nabire, Kabupaten Nduga, Kabupaten Paniai, Kabupaten Pegunungan Bintang, Kabupaten Puncak, Kabupaten Puncak Jaya, Kabupaten Sarmi, Kabupaten Supiori, Kabupaten Tolikara, Kabupaten Waropen, Kabupaten Yahukimo, Kabupaten Yalimo, Kota Jayapura
Sulawesi Tengah	Kabupaten Banggai, Kabupaten Banggai Kepulauan, Kabupaten Banggai Laut, Kabupaten Buol, Kabupaten Donggala, Kabupaten Morowali, Kabupaten Morowali Utara, Kabupaten Parigi Moutong, Kabupaten Poso, Kabupaten Sigi, Kabupaten Tojo Una-Una, Kabupaten Toli-Toli, Kota Palu
Sulawesi Selatan	Kabupaten Bantaeng, Kabupaten Barru, Kabupaten Bone, Kabupaten Bulukumba, Kabupaten Enrekang, Kabupaten Gowa, Kabupaten Jeneponto, Kabupaten Selayar (Kepulauan Selayar), Kabupaten Luwu, Kabupaten Luwu Timur, Kabupaten Luwu Utara, Kabupaten Maros, Kabupaten Pangkajene Kepulauan, Kabupaten Pinrang, Kabupaten Sidenreng Rappang (Sidrap), Kabupaten Sinjai, Kabupaten Soppeng, Kabupaten Takalar, Kabupaten Tana Toraja, Kabupaten Toraja Utara, Kabupaten Wajo, Kota Palopo, Kota Parepare
Aceh	Kabupaten Aceh Barat, Kabupaten Aceh Barat Daya, Kabupaten Aceh Besar, Kabupaten Aceh Jaya, Kabupaten Aceh Selatan, Kabupaten Aceh Singkil, Kabupaten Aceh Tamiang, Kabupaten Aceh Tengah, Kabupaten Aceh Tenggara, Kabupaten Aceh Timur, Kabupaten Aceh Utara, Kabupaten Bener Meriah, Kabupaten Bireuen, Kabupaten Gayo Lues, Kabupaten Nagan Raya, Kabupaten Pidie, Kabupaten Pidie Jaya, Kabupaten Simeulue, Kota Banda Aceh, Kota Langsa, Kota Lhokseumawe, Kota Sabang, Kota Subulussalam

lanjutan...

Sumatra Utara	Kabupaten Asahan, Kabupaten Batu Bara, Kabupaten Dairi, Kabupaten Humbang Hasundutan, Kabupaten Karo, Kabupaten Labuhanbatu, Kabupaten Labuhanbatu Selatan, Kabupaten Labuhanbatu Utara, Kabupaten Langkat, Kabupaten Mandailing Natal, Kabupaten Nias, Kabupaten Nias Barat, Kabupaten Nias Selatan, Kabupaten Nias Utara, Kabupaten Padang Lawas, Kabupaten Padang Lawas Utara, Kabupaten Pakpak Bharat, Kabupaten Samosir, Kabupaten Serdang Bedagai, Kabupaten Simalungun, Kabupaten Tapanuli Selatan, Kabupaten Tapanuli Tengah, Kabupaten Tapanuli Utara, Kabupaten Toba Samosir, Kota Binjai, Kota Gunungsitoli, Kota Padang Sidempuan, Kota Pematangsiantar, Kota Sibolga, Kota Tanjung Balai, Kota Tebing Tinggi
Riau	Kabupaten Bengkalis, Kabupaten Indragiri Hilir, Kabupaten Indragiri Hulu, Kabupaten Kampar, Kabupaten Kepulauan Meranti, Kabupaten Kuantan Singingi, Kabupaten Pelalawan, Kabupaten Rokan Hilir, Kabupaten Rokan Hulu, Kabupaten Siak, Kota Dumai, Kota Pekanbaru
Jambi	Kabupaten Batanghari, Kabupaten Bungo, Kabupaten Kerinci, Kabupaten Merangin, Kabupaten Muaro Jambi, Kabupaten Sarolangun, Kabupaten Tanjung Jabung Barat, Kabupaten Tanjung Jabung Timur, Kabupaten Tebo, Kota Jambi, Kota Sungai Penuh
Bengkulu	Kabupaten Bengkulu Selatan, Kabupaten Bengkulu Tengah, Kabupaten Bengkulu Utara, Kabupaten Kaur, Kabupaten Kepahiang, Kabupaten Lebong, Kabupaten Muko Muko, Kabupaten Rejang Lebong, Kabupaten Seluma, Kota Bengkulu
Lampung	Kabupaten Lampung Barat, Kabupaten Lampung Selatan, Kabupaten Lampung Timur, Kabupaten Lampung Utara, Kabupaten Mesuji, Kabupaten Pesawaran, Kabupaten Pesisir Barat, Kabupaten Pringsewu, Kabupaten Tulang Bawang, Kabupaten Tulang Bawang Barat, Kabupaten Way Kanan, Kota Bandar Lampung, Kota Metro
Kepulauan Bangka Belitung	Kabupaten Bangka, Kabupaten Bangka Barat, Kabupaten Bangka Selatan, Kabupaten Bangka Tengah, Kabupaten Belitung, Kabupaten Belitung Timur, Kota Pangkal Pinang, Kabupaten Bintan, Kabupaten Karimun, Kabupaten Kepulauan Anambas, Kabupaten Lingga, Kabupaten Natuna, Kota Tanjung Pinang
Cluster 2 (Rendah)	
DKI Jakarta	Kota Adm. Jakarta Barat, Kota Adm. Jakarta Selatan, Kota Adm. Jakarta Timur, Kota Adm. Jakarta Utara
Jawa Barat	Kabupaten Bandung, Kabupaten Bandung Barat, Kabupaten Bekasi, Kabupaten Bogor, Kabupaten Cianjur, Kabupaten Cirebon, Kabupaten Garut, Kabupaten Indramayu, Kabupaten Karawang, Kabupaten Majalengka, Kabupaten Subang, Kabupaten Sukabumi, Kabupaten Tasikmalaya, Kota Bandung, Kota Bekasi, Kota Depok
Jawa Tengah	Kabupaten Banyumas, Kabupaten Brebes, Kabupaten Cilacap, Kabupaten Kebumen, Kabupaten Pemalang, Kabupaten Tegal, Kota Semarang
Jawa Timur	Kabupaten Banyuwangi, Kabupaten Gresik, Kabupaten Jember, Kabupaten Jombang, Kabupaten Kediri, Kabupaten Malang, Kabupaten Pasuruan, Kabupaten Sidoarjo, Kota Surabaya
Banten	Kabupaten Lebak, Kabupaten Serang, Kabupaten Tangerang, Kota Cilegon, Kota Tangerang Selatan
Nusa Tenggara Barat	Kabupaten Lombok Tengah, Kabupaten Lombok Timur, Kota Makassar, Kabupaten Deli Serdang, Kota Medan
Lampung	Kabupaten Lampung Tengah, Kabupaten Tanggamus
Kepulauan Riau	Kota Batam

IV. KESIMPULAN

Berdasarkan penelitian yang telah dilakukan, dapat disimpulkan bahwa penggunaan metode *elbow* untuk membantu algoritma K-Means dalam mengelompokkan kabupaten/kota di Indonesia berdasarkan faktor penyebab stunting pada balita menghasilkan 2 *cluster* sebagai cluster terbaik dengan nilai selisih *Sum of Square Error* (SSE) sebesar 1401.5156, dimana *cluster* 1 merupakan *cluster* dengan faktor penyebab *stunting* tinggi yang terdiri dari 324 kabupaten/kota, dan *cluster* 2 merupakan *cluster* dengan faktor penyebab *stunting* rendah yang terdiri dari 49 kabupaten/kota.

PUSTAKA

- [1] Kemenkes RI, Buletin Stunting. Jakarta: Kementerian Kesehatan RI, 2018.
- [2] BPS, "Laporan Indeks Khusus Penanganan Stunting 2018-2019," Jakarta, 2020. [Online]. Available: <https://www.bps.go.id/publication/2020/12/01/fa48ee93a717baed2370d84a/laporan-indeks-khusus-penanganan-stunting-2018-2019.html>
- [3] D. A. Widyaningrum and D. A. Romadhoni, "Riwayat Anemia Kehamilan dengan Kejadian Stunting pada Balita di Desa Ketandan Dagangan Madiun," *Medica Majapahit*, vol. 10, no. 2, 2018.
- [4] Winarti, "Hubungan Antara Asupan Protein, Vitamin A, Zink, dan Riwayat ISPA dengan Kejadian Stunting pada Balita Usia 2-5 Tahun di Desa Wonorejo Kecamatan Pringapus Kabupaten Semarang," *J. Gizi dan Kesehat.*, vol. 12, no. 1, 2020.
- [5] A. Sutriyawan, R. D. Kurniawati, S. Rahayu, and J. Habibi, "Hubungan Status Imunisasi dan Riwayat Penyakit Infeksi dengan kejadian Stunting pada Balita: Studi Retrospektif," *J. Midwifery*, vol. 8, no. 2, 2020.
- [6] W. R. Hidayani, "Riwayat Penyakit Infeksi yang Berhubungan dengan Stunting di Indonesia : Literature Review," 2020.
- [7] WHO, "World Health Statistics Data Visualizations Dashboard," 2019. [Online]. Available: <https://apps.who.int/gho/data/node.sdg.2-2-viz-1?lang=en>.
- [8] BPS, Laporan Pelaksanaan Integrasi Susenas Maret 2019 dan SSGBI Tahun 2019. Jakarta: Badan Pusat Statistik, 2019.
- [9] Mursalim, Purwanto, and M. A. Soeleman, "Penentuan Centroid Awal Pada Algoritma K-Means Dengan Dynamic Artificial Chromosomes Genetic Algorithm Untuk Tuberculosis Dataset," *Techno.Com*, vol. 20, no. 1, pp. 97–108, 2021.
- [10] A. T. Rahman, "Coal Trade Data Clustering Using K-Means (Case Study Pt. Global Bangkit Utama)," *Informasi, ITSMART J. Teknol. dan*, vol. 6, no. 1, pp. 24–31, 2017.
- [11] W. Widayani and H. Harliana, "Perbandingan Algoritma K-Means dan SFCM Pada Pengelompokkan Rumah Tangga Miskin," *J. Sains dan Inform.*, vol. 6, no. 1, pp. 1–9, 2020.
- [12] I. Kamila, U. Khairunnisa, and M. Mustakim, "Perbandingan Algoritma K-Means dan K-Medoids untuk Pengelompokan Data Transaksi Bongkar Muat di Provinsi Riau," *J. Ilm. Rekayasa dan Manaj. Sist. Inf.*, vol. 5, no. 1, p. 119, 2019.
- [13] M. Nishom and M. Y. Fathoni, "Implementasi Pendekatan Rule-Of-Thumb untuk Optimasi Algoritma K-Means Clustering," *J. Inform. J. Pengemb. IT*, vol. 3, no. 2, pp. 237–241, 2018.
- [14] A. Winarta and W. J. Kurniawan, "Optimasi Cluster K-Means Menggunakan Metode Elbow Pada Data Pengguna Narkoba Dengan Pemrograman Python," *J. Tek. Inform. Kaputama*, vol. 5, no. 1, pp. 113–119, 2021.
- [15] N. L. W. S. R. Ginantra et al., *Data Mining dan Penerapan Algoritma*. Medan: Yayasan Kita Menulis, 2021.