

Penerapan Metode K-Medoids untuk Menentukan Status Gizi Balita di Puskesmas Dermayu

Alon Santoso

Universitas Dehasen Bengkulu

Indra Kanedi

Universitas Dehasen Bengkulu

Deri Lianda

Universitas Dehasen Bengkulu

Alamat : Jl. Meranti Raya No. 32 Kota Bengkulu 38228 Telp. (0736) 22027, 26957 Fax. (0736) 341139

*Korespondensi penulis: alonsantoso.politeknikpratama.ac.id

Abstract—The nutritional condition of children under five is one of the parameters of the state of public health in each region. Good nutrition in toddlers has an important influence on normal growth, physical development and intelligence in children, with good nutrition the body is not easily attacked by disease, infection, and is protected from chronic diseases. So there is a need for a system to find out the nutritional status of toddlers in a region as a source of information. input for the government and policy holders in the field of public health to prevent and overcome malnutrition in children under five. This research applies data mining for clustering the nutritional status of toddlers at the Dermayu Community Health Center using the K-Medoids algorithm method. This research method uses the waterfall method. Based on the results of this research, the nutritional status values of toddlers at the Dermayu Community Health Center can be clustered using the K-Medoids algorithm through two parameters: Toddler Weight (BB) and Toddler Height (TB), which are divided into 5 clusters, namely obesity, over nutrition, good nutrition, malnutrition and malnutrition to help the performance of community health centers and parents of toddlers in early handling of toddlers' nutritional conditions. From these results, it is known that there are still 30% of toddlers who are obese and 11% of toddlers who are malnourished, so there is a need for assistance from the relevant health centers for parents of toddlers so that the number of toddlers who are malnourished can decrease in the following year.

Keywords: Nutritional Status, K-Medoids, PHP MySQL

Abstrak— Kondisi gizi balita menjadi salah satu parameter keadaan kesehatan masyarakat dalam setiap wilayah. Gizi yang baik pada balita berpengaruh penting terhadap pertumbuhan normal, perkembangan fisik dan kecerdasan pada anak, dengan gizi yang baik tubuh tidak mudah terkena serangan penyakit, infeksi, dan terlindungi dari penyakit kronis. Sehingga perlunya sebuah sistem untuk mengetahui keadaan gizi balita di suatu wilayah sebagai bahan masukan bagi pemerintah maupun pemegang kebijakan dalam bidang kesehatan masyarakat untuk melakukan pencegahan dan penanggulangan gizi buruk pada balita. Penelitian ini menerapkan data mining untuk *clustering* status gizi balita di Puskesmas Dermayu dengan menggunakan metode Algoritma K-Medoids, metode penelitian ini menggunakan metode *waterfall*. Berdasarkan hasil penelitian ini bahwa nilai status gizi balita di Puskesmas Dermayu dapat diklusterisasikan dengan menggunakan algoritma K-Medoids melalui dua parameter Berat Badan Balita (BB) dan Tinggi Badan Balita (TB) dimana dibagi menjadi 5 cluster yaitu obesitas, gizi lebih, gizi baik, gizi kurang dan gizi buruk guna membantu kinerja para puskesmas dan Orang Tua balita dalam penanganan dini kondisi nilai gizi balita. Dari hasil tersebut diketahui masih terdapat 30% balita obesitas serta 11% balita kekurangan gizi sehingga perlu adanya pendampingan dari puskesmas terkait kepada orang tua balita sehingga jumlah balita yang kekurangan gizi dapat menurun di tahun berikutnya.

Kata Kunci : Status Gizi, K-Medoids, PHP MySQL

PENDAHULUAN

Kondisi gizi balita menjadi salah satu parameter keadaan kesehatan masyarakat dalam setiap wilayah. Gizi yang baik pada balita berpengaruh penting terhadap pertumbuhan normal,

perkembangan fisik dan kecerdasan pada anak, dengan gizi yang baik tubuh tidak mudah terkena serangan penyakit, infeksi, dan terlindungi dari penyakit kronis (Kemenkes, 2014). Kurang gizi pada balita tidak terjadi secara tiba-tiba, tetapi diawali dengan keterbatasan kenaikan berat badan yang tidak cukup. Perubahan berat badan balita dari waktu ke waktu merupakan petunjuk awal perubahan status gizi balita. Sehingga perlunya sebuah sistem untuk mengetahui keadaan gizi balita di suatu wilayah sebagai bahan masukan bagi pemerintah maupun pemegang kebijakan dalam bidang kesehatan masyarakat untuk melakukan pencegahan dan penanggulangan gizi buruk pada balita.

Pengelompokan status gizi balita di Puskesmas Dermayu masih menggunakan sistem manual, yaitu dengan menghitung satu persatu data tersebut. Data tersebut diolah secara manual untuk mendapatkan hasil status gizi pada balita. Penelitian ini bertujuan untuk melakukan perhitungan gizi balita secara otomatis dengan menggunakan aplikasi, sehingga dapat mengoptimalkan dan mempermudah pihak Puskesmas dalam melakukan pengelompokan status gizi balita.

Penelitian ini menggunakan teknik *data mining* yaitu proses pengolahan data dengan baik serta mendapatkan hasil perhitungan yang tepat dan merupakan ekstraksi informasi dari sejumlah data besar untuk mengidentifikasi informasi yang tersembunyi serta memfasilitasi pengetahuan secara langsung (T. Velmurugan. 2019). Salah satu teknik *data mining* yaitu *clustering* (D. U. Iswavigra, dkk. 2021) yang merupakan teknik statistik multidimensi bertujuan untuk mengumpulkan individu yang serupa ke dalam kelas-kelas yang homogen berdasarkan nilai-nilai yang diamati dalam sekumpulan variabel. Kelas yang dihasilkan dapat diatur sesuai dengan berbagai struktur (R. Anjariansyah dan A. Triayudi, 2022).

Penggunaan algoritma *K-Medoids* dalam penelitian ini untuk memecahkan permasalahan *clustering*. Metode K-Medoids adalah salah satu metode pengelompokan dalam data mining, algoritma ini menggunakan objek pada kumpulan objek untuk mewakili cluster dan cukup efisien dalam dataset yang kecil (Karmila, dkk. 2019). Metode ini merupakan penggerombolan non-hirarki yang merupakan variasi dari metode K-Means, K-Medoids dapat mengatasi kelemahan K-Means yang cenderung sensitive terhadap penciran (*outliers*) yang mungkin menyimpang dari distribusi (Schubert dan Rousseeuw, 2019) dan bekerja dengan memisahkan dataset menjadi beberapa kelompok (S. K. Muruganandham, dkk. 2018).

Berdasarkan permasalahan tersebut maka penulis tertarik melakukan penelitian yang berjudul **“Penerapan Metode K-Medoids untuk Menentukan Status Gizi Balita di Puskesmas Dermayu”**.

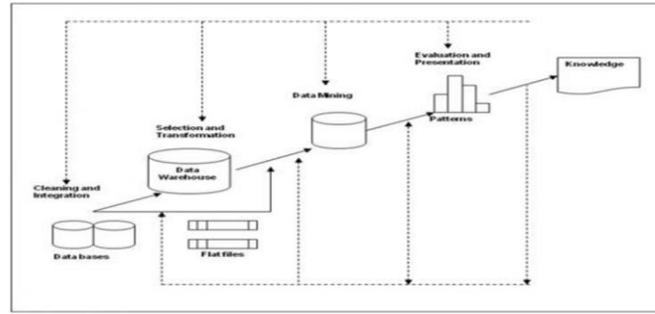
Berdasarkan ulasan dari latar belakang, maka dapat diambil suatu rumusan masalah yaitu bagaimana menerapkan data mining untuk clustering status gizi balita menggunakan metode K-Medoids sehingga dapat digunakan oleh pihak Puskesmas dalam melakukan perhitungan status gizi balita?

LANDASAN TIORI

Data mining merupakan suatu proses menemukan korelasi baru yang bermanfaat, pola dan trend dengan menambang sejumlah *repository* data dalam jumlah besar menggunakan teknologi pengenalan pola seperti statistic dan matematika (Karmila, dkk., 2019). Data mining biasanya digunakan dalam proses penambahan data yang besar dari kumpulan fakta yang terekam untuk mengetahui pola yang ada untuk menghasilkan sebuah output yang berupa informasi ataupun pengetahuan (H. Pohan dkk, 2021). Data mining merupakan ekstraksi informasi dari sejumlah data besar untuk mengidentifikasi informasi yang tersembunyi dan memfasilitasi pengetahuan secara langsung (T. Velmurugan. 2019). Selain itu, data mining merupakan domain dari beberapa ilmu yang menggabungkan pembelajaran mesin, pengenalan pola, statistik, basis data, dan metode visualisasi untuk mengatasi masalah pengambilan informasi dari database besar (S. Sahidatul, dkk. 2019) atau pola yang ditemukan dalam ilmu yang dapat dikenali datanya (D. A. Silitonga, dkk. 2019).

Data mining sangat diperlukan untuk bagaimana membantu instansi atau perusahaan dalam menemukan informasi-informasi penting di dalam sebuah basis data dengan proses atau teknik-teknik statistika, kecerdasan buatan, matematika, dan *machine learning* (Nugraha et al., 2018). Terdapat beberapa teknik algoritma data mining yang dapat digunakan untuk menemukan pola berupa pengetahuan dan informasi yaitu estimasi, asosiasi, klasifikasi, klasterisasi dan prediksi (F. Marisa, 2014). Berikut adalah tahapan-tahapan data mining:

1. *Data Cleaning*, merupakan tahap pembersihan data yang tidak konsisten.
2. *Data Integration*, merupakan langkah menggabungkan data dari beberapa sumber.
3. *Data Selection*, merupakan data yang tidak dikembalikan lagi ke database setelah proses data cleaning.
4. *Data Transformation*, merupakan data berubah atau bersatu menjadi bentuk yang tepat untuk menambang dengan ringkasan performa atau operasi regresi.
5. *Data Mining*, merupakan proses yang digunakan untuk mengolah suatu data dengan menggunakan metode.
6. *Evaluation and presentation*, merupakan pengidentifikasian pola berdasarkan tindakan yang digunakan.
7. *Knowledge*, yaitu sebuah hasil yang dicapai berupa pengetahuan atau sebuah informasi.



Gambar 2.1. Proses Data Mining

Algoritma K-Medoid merupakan salah satu algoritma *clustering* yang menggunakan objek sebagai perwakilan (medoid) dalam sebuah cluster untuk memecahkan dataset ke kelompok-kelompok diantara semua objek data (P. Halimatusakdiah, dkk. 2021). Metode Algoritma K-Medoids atau *Partitioning around Pams* (PAM) sebagai salah satu pengembangan dari metode Algoritma K-Means (D. Marlina, dkk. 2018) (N. R. Aeni, dkk. 2018) (Y.H. Crisnanto, dan G. Abdillah. 2015). Metode K-Medoids memiliki tujuan yang sama dengan K-Means, yaitu untuk meminimalkan jarak antara titik yang ditentukan sebagai pusat *cluster* dan titik data *cluster* (D. Hoosyar, dkk. 2020). Perbedaan dari kedua algoritma ini yaitu algoritma K-Medoids atau PAM menggunakan objek sebagai perwakilan (medoid) sebagai pusat cluster untuk setiap cluster, sedangkan K-Means menggunakan nilai rata-rata (mean) sebagai pusat cluster (D. F. Pramesti, dkk. 2017).

Metode K-Medoids bekerja dengan memisahkan dataset menjadi beberapa kelompok (S. K. Muruganandham, dkk. 2018) dan metode ini juga dapat meminimalkan jumlah kesamaan antara setiap objek dan titik referensi yang sesuai (Ogunde dan Ajibade, 2014). Metode K-Medoids bekerja dengan memisahkan dataset menjadi beberapa kelompok (S. K. Muruganandham, dkk. 2018) dan metode ini juga dapat meminimalkan jumlah kesamaan antara setiap objek dan titik referensi yang sesuai (Ogunde dan Ajibade, 2014). Metode K-Medoids merupakan salah satu metode pengelompokan dalam data mining, algoritma ini menggunakan objek pada kumpulan dari beberapa objek untuk mewakili cluster dan cukup efisien dalam dataset yang kecil (Karmila, dkk. 2019).

Langkah awal K-Medoids ialah mencari titik yang paling representatif (medoids) dalam dataset dengan menghitung jarak dari kelompok dalam semua kemungkinan kombinasi dari medoids sehingga jarak antar titik dalam suatu cluster kecil sedangkan jarak titik antar cluster besar. *K-Medoids* merupakan salah satu metode klaster non hierarki yang sederhana dan mudah diimplementasikan (A. Meimela, 2019). Sebelum memulai proses perhitungan K-Medoids, terlebih dahulu dilakukan tahapan *Preprocessing*. Pada tahapan *Preprocessing*, terdapat 3 proses yang dilakukan diantaranya: *Data Cleaning* yaitu proses penghapusan

terhadap data-data yang rusak, kosong, duplikat, tidak lengkap dan bentuk kesalahan-kesalahan data lainnya. Transformasi data yaitu proses merubah dan mentransformasi format data yang menjadi format data dalam bentuk numerik atau membuat inisialisasi, dan normalisasi data yaitu melakukan normalisasi data dengan cara mengurangi nilai bobot per *cluster* dengan nilai Min pada *cluster* tersebut kemudian membaginya dengan hasil pengurangan antara nilai Max dan Min *cluster* (D. U. Iswavigra, dkk. 2021). Pada metode K-Medoids, ada beberapa perhitungan dan langkah-langkah yang harus diselesaikan yaitu (E. Irwansyah, dkk. 2020) (D. A. Silitonga, dkk. 2019):

1. Menentukan nilai k, yang akan menjadi jumlah *cluster*
2. Memilih secara acak medoid awal sebanyak k dari n data
3. Menghitung jarak masing-masing objek ke medoids sementara menggunakan persamaan *Euclidian Distance*

$$JED = \sqrt{\sum_{i=1}^n (x_i - y_i)^2} \quad ; 1, 2, 3 \dots n \quad (1)$$

Keterangan:

JED : Jarak *Euclidian Distance*

x_i : Nilai Medoid awal pada dimensi 1

y_i : Nilai Objek pada data pertama

n : Jumlah objek

4. Menandai jarak minimum objek ke medoids dan hitung total kedekatannya.
5. Menentukan anggota *cluster* pada medoids awal.
6. Melakukan iterasi medoids baru dengan memilih kembali secara acak medoids baru sebanyak k dari n data (lakukan tahapan seperti sebelumnya).
7. Langkah terakhir yaitu menghitung total simpangan (S) dengan mencari selisih antara total kedekatan medoids baru dengan total kedekatan medoids lama. Jika total simpangan $S > 0$, maka proses *clustering* berhenti. Tetapi jika $S < 0$, maka cari medoids baru.

PEMBAHASAN

Penentuan status gizi dilakukan dengan mengembangkan sistem yang sudah ada, yaitu mengumpulkan data-data yang dibutuhkan kemudian diinput ke sistem yang baru. Sistem baru tidak hanya menggunakan data Umur (U) dan Berat Badan (BB), tetapi ditambahkan dengan data Tinggi Badan (TB) balita agar sesuai dengan parameter status gizi yang beracuan pada *anthropometri*.

Penelitian ini dilakukan berdasarkan analisis permasalahan pada Puskesmas Dermayu dalam menentukan status gizi balita yang masih menggunakan sistem manual. Dari permasalahan tersebut, maka dibutuhkannya sistem baru pada Puskesmas Dermayu dalam menentukan gizi balita. Sistem baru ini melakukan pembuatan aplikasi yang dapat mengolah data lebih efisien, pengolahan data untuk menampilkan status gizi balita secara otomatis,

sehingga dapat mempermudah tenaga kesehatan pada Puskesmas Dermayu dan orang tua balita untuk dapat mengetahui status gizi balita.

Penelitian diawali dengan pengumpulan data-data balita di daerah Puskesmas Dermayu yang berupa data Umur (U), Berat Badan (BB) dan Tinggi Badan (TB) pada balita. Data yang diperoleh kemudian dilakukannya data *cleaning* yaitu memilih data balita rentang umur 6 sampai 60 bulan dan memenuhi data Berat Badan (BB) dan Tinggi Badan (TB). Data yang telah dipilih, selanjutnya dilakukan transformasi data yaitu proses merubah data dalam bentuk numerik atau membuat inisialisasi. Setelah dilakukannya tahap *cleaning* data dan transformasi data, kemudian melakukan normalisasi data yaitu melakukan normalisasi data dengan mengurangi nilai bobot per *cluster* dengan nilai Min pada *cluster* tersebut kemudian membaginya dengan hasil pengurangan antara nilai Max dan Min *cluster*.

Data yang telah didapatkan kemudian di proses menggunakan metode K-Medoids, dengan langkah-langkah:

1. Menandai jarak minimum objek ke medoids dan hitung total Menentukan nilai k, yang akan menjadi jumlah *cluster*
2. Memilih secara acak medoid awal sebanyak k dari n data
3. Menghitung jarak masing-masing objek ke medoids sementara menggunakan persamaan (1)
4. kedekatannya.
5. Menentukan anggota *cluster* pada medoids awal.
6. Melakukan iterasi medoids baru dengan memilih kembali secara acak medoids baru sebanyak k dari n data (lakukan tahapan seperti sebelumnya).
7. Langkah terakhir yaitu menghitung total simpangan (S) dengan mencari selisih antara total kedekatan medoids baru dengan total kedekatan medoids lama. Jika total simpangan $S > 0$, maka proses *clustering* berhenti. Tetapi jika $S < 0$, maka cari medoids baru.

Persamaan rumus yang tertera berikut contoh perhitungan algoritma K-Medoids.

Jumlah data yang digunakan diambil dari sampel data di desa Dermayu dengan usia > 6 sampai ≤ 60 Bulan data tersebut dapat dilihat pada tabel 3.1.

| No | Nama | Posyandu | Umur (Bulan) | BB | TB |
|----|--------|------------|--------------|------|-----|
| 1 | Desta | Posyandu 1 | 42 | 12.7 | 91 |
| 2 | Aura | Posyandu 1 | 41 | 12.8 | 94 |
| 3 | Nazwa | Posyandu 2 | 39 | 16.8 | 98 |
| 4 | Arisa | Posyandu 2 | 33 | 13.4 | 94 |
| 5 | Evelyn | Posyandu 3 | 24 | 10.8 | 85 |
| 6 | Amira | Posyandu 3 | 24 | 10.3 | 103 |
| 7 | Farah | Posyandu 4 | 24 | 10.3 | 103 |
| 8 | Hasna | Posyandu 4 | 48 | 16.3 | 104 |
| 9 | Kania | Posyandu 5 | 45 | 15.7 | 100 |
| 10 | Aira | Posyandu 5 | 44 | 26.5 | 104 |
| 11 | Adinda | Posyandu 6 | 48 | 13.7 | 95 |

| | | | | | |
|----|---------------------|------------|----|------|-----|
| 12 | Alinda | Posyandu 6 | 48 | 12.7 | 98 |
| 13 | Raya | Posyandu 6 | 45 | 17.4 | 98 |
| 14 | Dinda | Posyandu 1 | 45 | 17.4 | 98 |
| 15 | Nabila Sifo | Posyandu 1 | 42 | 12.7 | 91 |
| 16 | Farrelino | Posyandu 2 | 41 | 12.8 | 94 |
| 17 | Jesson Huki | Posyandu 2 | 39 | 16.6 | 98 |
| 18 | Raka Aditya M | Posyandu 2 | 15 | 9.7 | 76 |
| 19 | Xavetia | Posyandu 3 | 14 | 7.5 | 73 |
| 20 | Yemima Adelia | Posyandu 4 | 12 | 8.1 | 75 |
| 21 | Nadia Arum N | Posyandu 5 | 12 | 7.1 | 71 |
| 22 | Yosep Enrino | Posyandu 5 | 10 | 9.4 | 77 |
| 23 | Liona Cresya | Posyandu 5 | 9 | 8 | 66 |
| 24 | Faiha Cataleya | Posyandu 5 | 9 | 10 | 68 |
| 25 | Trisya Afiqah | Posyandu 1 | 8 | 9.3 | 70 |
| 26 | Gita Oliviana Putri | Posyandu 1 | 51 | 15.4 | 100 |
| 27 | Najma Azkia M | Posyandu 2 | 50 | 15.1 | 99 |
| 28 | Andika B | Posyandu 3 | 49 | 12.2 | 95 |
| 29 | Dewangga Yusuf | Posyandu 3 | 49 | 15.5 | 100 |
| 30 | Hafids Fahmi | Posyandu 4 | 49 | 17.2 | 103 |

Tabel 3.1 Contoh Data Balita

Data yang ada pada tabel 3.1 tidak dapat langsung dilakukan pemrosesan dikarenakan terdapat besaran angka yang cukup jauh antara variabel tinggi badan, berat badan dan umur. Perbedaan jarak atau besaran angka yang cukup jauh ini dapat menyulitkan dalam proses pengelompokan. Salah satu solusi yang digunakan untuk memperkecil besaran angka antar variabel adalah dengan melakukan normalisasi angka-angka yang ada di variabel tinggi badan, berat badan dan umur menggunakan persamaan 3.1.

$$\text{nilai normalisasi} = \frac{(\text{nilai awal} - \text{nilai minimal})}{(\text{nilai maksimal} - \text{nilai minimal})} \quad (3.1)$$

Nilai variabel tinggi badan, berat badan dan umur akan dinormalisasi ke dalam rentang 0–1. Normalisasi angka pada tiap variabel ini sangat dibutuhkan sebelum proses perhitungan nilai *centroid* oleh algoritma *K-Medoids* agar tidak ada parameter yang mendominasi dalam perhitungan jarak antar data (Atthina & Iswari, 2015). Adapun tahapan yang dilakukan untuk proses normalisasi adalah:

- a. Mencari nilai maksimum dan minimum untuk variabel tinggi badan (X)

$$\text{Nilai maksimum } (X_{\text{maks}}) = 104$$

$$\text{Nilai minimum } (X_{\text{min}}) = 66$$

- b. Menghitung nilai normalisasi menggunakan persamaan 2.4.

$$X_1 = (X_{\text{balita1}} - X_{\text{min}}) /$$

$$(X_{\text{maks}} - X_{\text{min}}) = (91 - 66) / (104 - 66) = 0.6579$$

$$X_2 = (X_{\text{balita2}} - X_{\text{min}}) /$$

$$(X_{\text{maks}} - X_{\text{min}}) = (94 - 66) / (104 - 66) = 0.7368$$

$$X_3 = (X_{balita3} - X_{min}) / (X_{maks} - X_{min}) = (98-66) / (104-66) = 0.8421$$

Perhitungan yang sama dilakukan hingga balita ke-30. Perhitungan dan persamaan yang sama digunakan untuk melakukan normalisasi variabel berat badan dan umur Hasil dari normalisasi pada variabel berat badan, tinggi badan dan umur dapat dilihat pada tabel 3.2.

| No | Nama | Posyandu | Umur (bln) | BB | TB | Rata-Rata |
|----|---------------|------------|---------------|---------------|---------------|---------------|
| 1 | Desta | Posyandu 1 | 0.790697 7 | 0.288659 2 | 0.657894 7 | 0.579084 1 |
| 2 | Aura | Posyandu 1 | 0.767441 9 | 0.293814 4 | 0.736842 1 | 0.599366 1 |
| 3 | Nazwa | Posyandu 2 | 0.720930 2 | 0.5 | 0.842105 3 | 0.687678 5 |
| 4 | Arisa | Posyandu 2 | 0.581395 3 | 0.324742 3 | 0.736842 1 | 0.547659 9 |
| 5 | Evelyn | Posyandu 3 | 0.372093 | 0.190721 6 | 0.5 | 0.354271 6 |
| 6 | Amira | Posyandu 3 | 0.372093 | 0.164948 5 | 0.973684 2 | 0.503575 2 |
| 7 | Farah | Posyandu 4 | 0.372093 | 0.164948 5 | 0.973684 2 | 0.503575 2 |
| 8 | Hasna | Posyandu 4 | 0.930232 6 | 0.474226 8 | 1 | 0.801486 5 |
| 9 | Kania | Posyandu 5 | 0.860465 1 | 0.443299 | 0.894736 8 | 0.732833 6 |
| 10 | Aira | Posyandu 5 | 0.837209 3 | 1 | 1 | 0.945736 4 |
| 11 | Adinda | Posyandu 6 | 0.930232 6 | 0.340206 2 | 0.763157 9 | 0.677865 5 |
| 12 | Alinda | Posyandu 6 | 0.930232 6 | 0.288659 8 | 0.842105 3 | 0.686999 2 |
| 13 | Raya | Posyandu 6 | 0.860465 1 | 0.530927 8 | 0.842105 3 | 0.744499 4 |
| 14 | Dinda | Posyandu 1 | 0.860465 1 | 0.530927 8 | 0.842105 3 | 0.744499 4 |
| 15 | Nabila Sifo | Posyandu 1 | 0.790697 7 | 0.288659 8 | 0.657894 7 | 0.579084 1 |
| 16 | Farrelino | Posyandu 2 | 0.767441 9 | 0.293814 4 | 0.736842 1 | 0.599366 1 |
| 17 | Jesson Huki | Posyandu 2 | 0.720930 2 | 0.489690 7 | 0.842105 3 | 0.186656 4 |
| 18 | Raka Aditya M | Posyandu 2 | 0.162790 7 | 0.020618 6 | 0.184210 5 | 0.114788 |
| 19 | Xavetia | Posyandu 3 | 0.139534 9 | 0.051546 4 | 0.236842 1 | 0.127137 3 |
| 20 | Yemima Adelia | Posyandu 4 | 0.093023 3 | 0 | 0.131578 9 | 0.074867 4 |
| 21 | Nadia Arum N | Posyandu 5 | 0.093023 3 | 0.118556 7 | 0.289473 7 | 0.075124 |
| 22 | Yosep Enrino | Posyandu 5 | 0.046511 6 | 0.463918 | 0.289473 7 | 0.151514 |

| | | | | | | |
|----|------------------|------------|---------------|---------------|---------------|---------------|
| 23 | Liona Cresya | Posyandu 5 | 0.023255 8 | 0.046391 8 | 0 | 0.023215 9 |
| 24 | Faiha Cataleya | Posyandu 5 | 0.023255 8 | 0.149484 5 | 0.052631 6 | 0.075124 |
| 25 | Trisya Afiqah | Posyandu 1 | 0 | 0.113402 1 | 0.105263 2 | 0.072888 4 |
| 26 | Gita Oliviana | Posyandu 1 | 1 | 0.427835 1 | 0.894736 8 | 0.774190 6 |
| 27 | Najma Azkia M | Posyandu 2 | 0.976744 2 | 0.412371 1 | 0.868421 1 | 0.752512 1 |
| 28 | Andika B | Posyandu 3 | 0.953488 4 | 0.262886 6 | 0.763157 9 | 0.659844 3 |
| 29 | Dewangga | Posyandu 3 | 0.953488 4 | 0.432989 7 | 0.894736 8 | 0.760405 |
| 30 | Hafids Fahmi | Posyandu 4 | 0.953488 4 | 0.520618 6 | 0.973684 2 | 0.815930 4 |

Tabel 3.2 Hasil Normalisasi Data Balita

Setelah angka pada masing-masing variabel dilakukan normalisasi, langkah selanjutnya adalah menentukan jumlah kelompok atau *cluster* Ke 30 data balita yang ada di tabel 3.1 akan dikelompokkan ke dalam 5 *cluster* yaitu: Gizi buruk, Gizi Sedang, Gizi baik, Gizi lebih, Obesitas. Setelah jumlah *cluster* ditentukan, langkah selanjutnya adalah melakukan menentukan nilai initial *cluster medoids* untuk masing-masing cluster pada setiap variabelnya. Nilai *cluster medoids* pada iterasi yang pertama (perhitungan pertama kali) diberikan secara acak. Pada iterasi selanjutnya, nilai *medoids* (pengulangan ke-1 sampai dengan posisi normal/maksimal iterasi) diberikan dengan menghitung nilai rata-rata data pada setiap clusternya. Jika nilai *initial cluster medoids* yang baru sama dengan nilai *initial cluster medoids* yang baru maka proses iterasi dilanjutkan hingga nilai sama atau sampai dengan nilai maksimal iterasi yang telah ditetapkan sebelumnya (misalnya 100). Namun jika nilai *initial cluster medoids* yang baru sama dengan *initial cluster medoids* yang lama, proses pengelompokkan berhenti. Misalkan nilai *initial cluster medoids* ditunjukkan pada tabel 3.3.

Tabel 3.3 initial Kreteria

| No | Nama Initial | Status Gizi | Nilai |
|----|-----------------|-------------|-------------|
| 1 | Kreteria 1 (K1) | Gizi Buruk | 0.96 – 1 |
| 2 | Kreteria 1 (K2) | Gizi Kurang | 0.73 - 0.95 |
| 3 | Kreteria 1 (K3) | Gizi Baik | 0.49 - 0.72 |
| 4 | Kreteria 1 (K4) | Gizi Lebih | 0.35 - 0.48 |
| 5 | Kreteria 1 (K5) | Obesitas | 0.04 – 0.34 |

Nilai *initial cluster medoids* pada tabel 3.3 digunakan untuk menghitung jarak antara data dengan *centroid*. Persamaan yang digunakan untuk menghitung jarak pada penelitian ini adalah *Euclidean Distance* (persamaan 2.1).

Adapun contoh perhitungan jarak data ke-1 pada masing-masing cluster adalah:

$$d(x_1, c_1) = \sqrt{(x_1 - c_1)^2}$$

$$d(x_1, c_1) = \sqrt{(0.5790841 - 0.96)^2}$$

$$d(x_1, c_1) = 0.3808$$

$$d(x_1, c_2) = \sqrt{(x_1 - c_2)^2}$$

$$d(x_1, c_2) = \sqrt{(0.5790841 - 0.73)^2}$$

$$d(x_1, c_2) = 0.1489$$

$$d(x_1, c_3) = \sqrt{(x_1 - c_3)^2}$$

$$d(x_1, c_3) = \sqrt{(0.5790841 - 0.49)^2}$$

$$d(x_1, c_3) = 0.0713$$

$$d(x_1, c_4) = \sqrt{(x_1 - c_4)^2}$$

$$d(x_1, c_4) = \sqrt{(0.5790841 - 0.355)^2}$$

$$d(x_1, c_4) = 0.253$$

$$d(x_1, c_5) = \sqrt{(x_1 - c_5)^2}$$

$$d(x_1, c_5) = \sqrt{(0.5790841 - 0.04)^2}$$

$$d(x_1, c_5) = 0.4966$$

Persamaan dan perhitungan yang sama diterapkan di 30 data untuk mendapatkan jarak tiap data pada masing-masing cluster seperti pada tabel 3.4.

| No | Nama | Posyandu | Rata ² | Hasil | Status Gizi |
|----|---------------|------------|-------------------|-------|-------------|
| 1 | Desta | Posyandu 1 | 0.579 | 0.49 | Gizi Baik |
| 2 | Aura | Posyandu 1 | 0.599 | 0.49 | Gizi Baik |
| 3 | Nazwa | Posyandu 2 | 0.687 | 0.49 | Gizi Baik |
| 4 | Arisa | Posyandu 2 | 0.547 | 0.49 | Gizi Baik |
| 5 | Evelyn | Posyandu 3 | 0.354 | 0.48 | Gizi Lebih |
| 6 | Amira | Posyandu 3 | 0.503 | 0.49 | Gizi Baik |
| 7 | Farah | Posyandu 4 | 0.503 | 0.49 | Gizi Baik |
| 8 | Hasna | Posyandu 4 | 0.801 | 0.73 | Gizi Kurang |
| 9 | Kania | Posyandu 5 | 0.732 | 0.73 | Gizi Kurang |
| 10 | Aira | Posyandu 5 | 0.945 | 0.96 | Gizi Buruk |
| 11 | Adinda | Posyandu 6 | 0.677 | 0.49 | Gizi Baik |
| 12 | Alinda | Posyandu 6 | 0.686 | 0.73 | Gizi Kurang |
| 13 | Raya | Posyandu 6 | 0.744 | 0.73 | Gizi Kurang |
| 14 | Dinda | Posyandu 1 | 0.744 | 0.73 | Gizi Kurang |
| 15 | Nabila Sifo | Posyandu 1 | 0.579 | 0.49 | Gizi Baik |
| 16 | Farrelino | Posyandu 2 | 0.599 | 0.49 | Gizi Baik |
| 17 | Jesson Huki | Posyandu 2 | 0.186 | 0.04 | Obesitas |
| 18 | Raka Aditya M | Posyandu 2 | 0.114 | 0.04 | Obesitas |
| 19 | Xavetia | Posyandu 3 | 0.127 | 0.04 | Obesitas |
| 20 | Yemima Adelia | Posyandu 4 | 0.074 | 0.04 | Obesitas |
| 21 | Nadia Arum N | Posyandu 5 | 0.075 | 0.04 | Obesitas |
| 22 | Yosep Enrino | Posyandu 5 | 0.151 | 0.04 | Obesitas |

| | | | | | |
|----|---------------------|------------|-------|------|-------------|
| 23 | Liona Cresya | Posyandu 5 | 0.023 | 0.04 | Obesitas |
| 24 | Faiha Cataleya | Posyandu 5 | 0.075 | 0.04 | Obesitas |
| 25 | Trisya Afiqah | Posyandu 1 | 0.072 | 0.04 | Obesitas |
| 26 | Gita Oliviana Putri | Posyandu 1 | 0.774 | 0.73 | Gizi Kurang |
| 27 | Najma Azkia M | Posyandu 2 | 0.752 | 0.73 | Gizi Kurang |
| 28 | Andika B | Posyandu 3 | 0.659 | 0.49 | Gizi Baik |
| 29 | Dewangga Yusuf | Posyandu 3 | 0.760 | 0.73 | Gizi Kurang |
| 30 | Hafids Fahmi | Posyandu 4 | 0.815 | 0.73 | Gizi Kurang |

Tabel 3.4. Tabel hasil Cluster Medoids

Setelah masing-masing data dihitung jaraknya untuk tiap *cluster*, langkah selanjutnya adalah mengelompokkan data sesuai cluster-nya. Kelompok *cluster* suatu data diambil dari jarak terpendek data tersebut terhadap suatu *cluster*. Sebagai contoh untuk data balita 1 memiliki jarak 0.3809159 terhadap cluster 1 (Gizi Buruk). Pada cluster 2 (Gizi Sedang) memiliki jarak 0.1489455. Pada cluster 3 (Gizi Baik) memiliki jarak 0.0712868. Pada *cluster* 4 (Gizi Lebih) memiliki jarak 0.2529975. Dan pada cluster 5 (Obesitas) memiliki jarak 0.4966171. Dari ke-5 cluster tersebut, data balita 1 memiliki jarak terpendek dengan cluster 3 (Gizi baik) dengan nilai 0.0712868. Oleh karena itu data balita 1 masuk ke dalam cluster 1 (Gizi baik). Langkah yang sama diterapkan di ke-30 data untuk melakukan pengelompokan di iterasi 1. Pada iterasi selanjutnya, dilakukan langkah yang sama. Jika nilai *initial cluster medoids* sama dengan itersi sebelumnya maka proses dihentikan.

Setelah melakukan langkah-langkah tersebut, maka status gizi balita secara otomatis tampil. Sistem baru dalam menentukan status gizi balita pada Puskesmas Dermayu yang berbentuk Website dan telah sesuai serta terdapat seluruh variabel *anthropometri*, diharapkan dapat mempermudah pelaksana gizi pada Puskesmas Dermayu dan orang tua balita dalam mengetahui status gizi balita.

PEMBAHASAN

Sistem pendukung keputusan ini berbasis web yang dibangun khusus untuk user dalam memberikan rekomendasi keputusan dalam penentuan gizi balita dalam Penerapan Metode K-Medoids untuk Menentukan Status Gizi Balita di Puskesmas Dermayu, Pada sistem terdapat menu utama yang dilengkapi dengan beberapa menu lainnya termasuk menu perangkan yang dilakukan dengan metode K-Medoids untuk membantu proses perhitungan dan menghasilkan rekomendasi keputusan status gizi Balita, Model persoalan pada sistem ini akan menghasilkan rekomendasi nama-nama status gizi balita di puskesmas Dermayu yang

diurutkan berdasarkan ranking nilai bobot global Balita. Penggunaan sistem sesuai model persoalan yang telah dijelaskan pada tahap analisa sebelumnya.

Tampilan menu utama adalah tampilan yang menginformasikan tentang website dermayu dengan penerapan Metode K_Medoids untuk memutuskan Status Gizi Balita di Puskesmas Dermayu terdiri dari Menu Home, data, Proses, hasil, cetak dan Logout.



Gambar 4.5. Menu Utama

Tampilan menu data proses terdapat penentuan aplikasi proses metode K-Medoids seperti gambar 4.10.

| NO | NAMA | UMUR | BB | TG | RATA2 |
|----|---------|--------------|--------------|--------------|------------------|
| 1 | AIRA | 0.0000000000 | 1.0000000000 | 0.0000000000 | 0.333333333333 |
| 2 | Amira | 0.3333333333 | 0.0088235294 | 0.9870967742 | 0.44308454563333 |
| 3 | ARISA | 0.5833333333 | 0.1000000000 | 0.8709677419 | 0.5181003584 |
| 4 | AURA | 0.8055555556 | 0.0823529412 | 0.8709677419 | 0.58629207956667 |
| 5 | DESTA | 0.8333333333 | 0.0794117647 | 0.8322580645 | 0.58166772083333 |
| 6 | Evelin | 0.3333333333 | 0.0000000000 | 0.7548387097 | 0.36272401433333 |
| 7 | Farah | 0.3333333333 | 0.0088235294 | 0.9870967742 | 0.44308454563333 |
| 8 | Hasnath | 1.0000000000 | 0.1852941176 | 1.0000000000 | 0.73843137253333 |
| 9 | Kania | 0.9166666667 | 0.1676470588 | 0.9483870968 | 0.67756694076667 |
| 10 | NAZWA | 0.7500000000 | 0.2000000000 | 0.9225806452 | 0.6241935484 |

Gambar 4.10. Sub Menu Proses

Tampilan data proses dimana terdapat tabel normalisasi data balita dan tabel hasil Cluster Medoids seperti gambar dibawah ini.

| NO | NAMA | UMUR | BB | TG | RATA2 |
|----|---------|--------------|--------------|--------------|------------------|
| 1 | Amira | 0.0000000000 | 0.0441176471 | 0.9473684211 | 0.33049535666667 |
| 2 | ARISA | 0.3750000000 | 0.5000000000 | 0.4736842105 | 0.4495614035 |
| 3 | AURA | 0.7083333333 | 0.4117647059 | 0.4736842105 | 0.5312607499 |
| 4 | DESTA | 0.7500000000 | 0.3970588235 | 0.3157894737 | 0.48761699966667 |
| 5 | Evelin | 0.0000000000 | 0.0000000000 | 0.0000000000 | 0 |
| 6 | Farah | 0.0000000000 | 0.0441176471 | 0.9473684211 | 0.33049535666667 |
| 7 | Hasnath | 1.0000000000 | 0.9264705882 | 1.0000000000 | 0.97549019696667 |
| 8 | Kania | 0.8750000000 | 0.8382352941 | 0.7894736842 | 0.8342363261 |
| 9 | NAZWA | 0.6250000000 | 1.0000000000 | 0.6842105263 | 0.7697368421 |

| NO | NAMA | RATA2 | HASIL | KETERANGAN |
|----|---------|-------|-------|------------|
| 1 | Amira | 0.33 | 0.67 | GIZI BAK |
| 2 | ARISA | 0.45 | 0.55 | GIZI BAK |
| 3 | AURA | 0.53 | 0.47 | GIZI LEBIH |
| 4 | DESTA | 0.49 | 0.51 | GIZI BAK |
| 5 | Evelin | 0.00 | 1.00 | GIZI BURUK |
| 6 | Farah | 0.33 | 0.67 | GIZI BAK |
| 7 | Hasnath | 0.98 | 0.64 | GIZI BAK |
| 8 | Kania | 0.83 | 0.49 | GIZI BAK |
| 9 | NAZWA | 0.77 | 0.43 | GIZI LEBIH |

Gambar 4.11. Sub Menu Data Proses

KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian ini bahwa nilai status gizi balita di Puskesmas Dermayu dapat diklasterisasikan dengan menggunakan algoritma K-Medoids melalui dua parameter Berat Badan Balita (BB) dan Tinggi Badan Balita (TB) dimana dibagi menjadi 5 cluster yaitu obesitas, gizi lebih, gizi baik, gizi kurang dan gizi buruk guna membantu kinerja para puskesmas dan Orang Tua balita dalam penanganan dini kondisi nilai gizi balita. Dari hasil tersebut diketahui masih terdapat 30% balita obesitas serta 11% balita kekurangan gizi sehingga perlu adanya pendampingan dari puskesmas terkait kepada orang tua balita sehingga jumlah balita yang kekurangan gizi dapat menurun di tahun berikutnya.

DAFTAR PUSTAKA

- 1]. Desi Asima Silitonga., Agus Perdana Windarto., & Dedy Hartama, Sumarno. (2019). Penerapan Metode K-Medoid pada Pengelompokan Rumah Tangga Dalam Perlakuan Memilah Sampah Menurut Provinsi. Seminar Nasional Sains & Teknologi Informasi (SENSASI). ISBN: 978-602-52720-2-8 Hal: 313–318
- 2]. D. F. Pramesti, Lahan, M. Tanzil Furqon, and C. Dewi, “Implementasi Metode K-Medoids Clustering Untuk Pengelompokan Data Potensi Kebakaran Hutan/Lahan Berdasarkan Persebaran Titik Panas(Hotspot),” *J. Pengemb. Teknol. Inf. dan Ilmu Komput.*, vol. 1, no. 9, pp. 723–732, 2017.
- 3]. D. Marlina, N. Lina, A. Fernando, and A. Ramadhan, “Implementasi Algoritma K-Medoids dan K-Means untuk Pengelompokan Wilayah Sebaran Cacat pada Anak,” *J. CoreIT J. Has. Penelit. Ilmu Komputer dan Teknologi. Inf.*, vol. 4, no. 2, p. 64, 2018, doi: 10.24014/coreit.v4i2.4498.
- 4]. Dwi Utari Iswavigra, Sarjon Defit, Gunadi Widi Nurcahyo. *Data mining dalam Pengelompokan Penyakit Pasien dengan Metode K-Medoids*. 2021. Jurnal informasi dan teknologi. Vol. 3 No. 4, Hal: 181-189, e-ISSN: 2714-9730
- 5]. E. Prasetyo. *Konsep data mining dan aplikasi menggunakan matlab*. Yogyakarta: Andi Yogyakarta. 2012.
- 6]. F. Marisa, “Educational Data Mining (Konsep dan Penerapan),” *Teknologi and Information*. vol. 4, no. 2, pp. 90–97, 2014.
- 7]. Halimatusakdiah Pohan¹, Muhammad Zarlis², Eka Irawan³, Harly Okprana⁴, Yuegilion Pranayama Purba⁵. Penerapan Algoritma K-Medoids dalam Pengelompokan Balita Stunting di Indonesia. Jurnal Komputer dan Informatika. Volume 3 Nomor 2 November 2021, e-ISSN: 2722-4368
- 8]. Hooshyar, D., Yang, Y., Pedaste, M., and Huang, Y.-M. (2020). *Clustering Algorithms in an Educational Context: An Automatic Comparative Approach*. *IEEE Access*, 8, 146994–147014. doi: 10.1109/access.2020.3014948
- 9]. Irwansyah, E., Salim Pratama, E., & Ohhyver, M. (2020). *Clustering of Cardiovascular Disease Patients Using Data Mining Techniques with Principal Component Analysis and K-Medoids*. doi: 10.20944/preprints202008.0074.v

- 10]. Karmila, Agus Perdana Windarto, M. Fauzan Analisis Metode K-Medoid Pada Kasus Obesitas Balita Menurut Privinsi Di Indonesia. Prosiding Seminar Nasional Riset Information Science (SENARIS). Hal 528-536. 2019. ISSN: 2686-0260
- 11]. Kementerian kesehatan republic Indonesia. Pedoman gizi seimbang. Jakarta. 2014.
- 12]. Muruganandham, S. K., Sobyta, D., Nallusamy, S., Mandal, D. K., & Chakraborty, P. S. (2018). *Study on Leaf Segmentation Using K-Means and K-Medoid Clustering Algorithm for Identification of Disease. Indian Journal of Public Health Research & Development*, 9(5), 289. doi:10.5958/0976-5506.2018.00456.4
- 13]. N. R. Aeni *et al.*, “Algoritma Partitioning around Medoids dalam Mengelompokan Provinsi Di Indonesia Berdasarkan,” pp. 1–9, 2018.
- 14]. Ogunde and Ajibade, “A Data Mining System for Predicting University Students’ Graduation Grades Using ID3 Decision Tree Algorithm Ogunde A. O 1 and Ajibade D. A 1” *Comput. Sci. Inf. Technol.* vol. 2, no. 1, pp. 21–46, 2014.
- 15]. Schubert, E., & Rousseeuw, P. J. (2019). Faster K-Medoids Clustering: Improving the PAM, CLARA, and CLARANS Algorithms. *International Conference on Similarity Search aApplications*, 171–187.
- 16]. S. M. Andri, Yesi Novaria Kunang, “Implementasi Teknik Data Mining Untuk Memprediksi Tingkat Kelulusan,” *Semin. Nas. Inform. 2013 (semnasIF 2013) UPN”Veteran”*, vol. 2013, no. June 2016, pp. 56–63, 2013.
- 17]. S. Syahidatul Helma *et al.* “Clustering pada Data Fasilitas Pelayanan Kesehatan Kota Pekanbaru Menggunakan Algoritma K-Means,” *Puzzle Res. Data Technol. Fak. Sains dan Teknol.* , vol. 1, no. November, p. 4, 2019.
- 18]. T. Velmurugan, “Efficiency of k-Means and K-Medoids Algorithms for Clustering Arbitrary Data Points.”
- 19]. Y. H. Chrisnanto and G. Abdillah, “Penerapan algoritma partitioning around medoids (PAM) clustering untuk melihat gambaran umum kemampuan akademik mahasiswa,” *Semin. Nas. Teknol. Inf. dan Komun.* vol. 2015, no. Sentika, pp. 444–448, 2015.