

Analisis Pola Menu Program Makan Bergizi Gratis Menggunakan Algoritma Apriori

Arjon Samuel Sitio¹, Richard Parlindungan Simanjuntak², Sardo Pardingotan Sipayung³

^{1,2}Sistem Informasi, Fakultas Sains dan Teknologi, Universitas Tjut Nyak Dhien, Medan, Indonesia

³Sains Data, Fakultas Ilmu Komputer, Universitas Katolik Santo Thomas, Medan, Indonesia

Email: ¹arjonsitio@yahoo.com, ²richsparlin0@gmail.com, ³pinsarsiphom@gmail.com

ABSTRACT

The Free Nutritious Meals Program (MBG) requires data-driven evaluation to identify the regularity, diversity, and co-occurrence of menu components. This study aims to explore associations among MBG menu items and beneficiary groups using association rule mining with the Apriori algorithm. The research follows the Knowledge Discovery in Databases framework, covering data selection, preprocessing, binary transaction transformation, frequent-itemset mining, rule generation, evaluation, and visualization. The available dataset is a secondary illustrative transaction recap consisting of five menu-distribution records. A minimum support of 40% and a minimum confidence of 60% were applied; rule quality was assessed using support, confidence, and lift. Apriori was selected rather than FP-Growth or Eclat because the dataset is small, the item vocabulary is limited, and the level-wise candidate process is easier to audit and interpret for exploratory policy evaluation. The analysis produced 31 frequent itemsets and 67 association rules before redundancy filtering. Representative positive associations included Fish → Fruit, Milk → Elementary School, and Elementary School → Green Vegetables, while Rice → Green Vegetables had the highest support but a neutral lift of 1.00. Scatter and network visualizations clarified the strength and structure of the rules. The results demonstrate the usefulness of Apriori for transparent exploratory analysis, but the small illustrative dataset means that the findings should not be generalized to national MBG implementation. Larger multi-period datasets and direct comparisons with FP-Growth and Eclat are recommended.

Keywords: Free Nutritious Meals Program, Apriori, Association Rule Mining, Frequent Itemset, KDD.

ABSTRAK

Program Makan Bergizi Gratis (MBG) memerlukan evaluasi berbasis data untuk mengidentifikasi keteraturan, variasi, dan kemunculan bersama komponen menu. Penelitian ini bertujuan mengeksplorasi hubungan antaritem menu MBG dan kelompok penerima menggunakan association rule mining dengan algoritma Apriori. Penelitian mengikuti kerangka Knowledge Discovery in Database yang meliputi seleksi data, prapemrosesan, transformasi transaksi biner, pembentukan frequent itemset, pembentukan aturan, evaluasi, dan visualisasi. Dataset yang tersedia merupakan data sekunder berupa rekapitulasi contoh lima transaksi distribusi menu. Nilai minimum support ditetapkan 40% dan minimum confidence 60%, sedangkan kualitas aturan dinilai menggunakan support, confidence, dan lift. Apriori dipilih dibandingkan FP-Growth dan Eclat karena ukuran dataset kecil, jumlah item terbatas, serta proses pembentukan kandidat bertingkat lebih mudah ditelusuri dan diaudit untuk evaluasi kebijakan secara eksploratif. Analisis menghasilkan 31 frequent itemset dan 67 aturan asosiasi sebelum penyaringan redundansi. Asosiasi positif yang representatif antara lain Ikan → Buah, Susu → SD, dan SD → Sayur Hijau, sedangkan Nasi → Sayur Hijau memiliki support tertinggi tetapi lift netral sebesar 1,00. Scatter plot dan network graph memperjelas kekuatan serta struktur hubungan antaritem. Hasil menunjukkan bahwa Apriori berguna untuk analisis eksploratif yang transparan, tetapi jumlah transaksi yang terbatas menyebabkan temuan belum dapat digeneralisasikan terhadap implementasi MBG secara nasional. Penelitian berikutnya perlu menggunakan data multi-periode yang lebih besar dan membandingkan Apriori dengan FP-Growth serta Eclat.

Kata Kunci: Program Makan Bergizi Gratis, Apriori, Association Rule Mining, Frequent Itemset, KDD.

1. Pendahuluan

Program Makan Bergizi Gratis (MBG) merupakan intervensi pangan yang diarahkan untuk memperkuat pemenuhan gizi peserta didik. Dalam program distribusi makanan berskala luas, keberhasilan tidak cukup dinilai dari jumlah porsi yang tersalurkan. Evaluasi juga perlu memperhatikan konsistensi menu, keberagaman sumber pangan, keterkaitan antara makanan pokok, protein, sayur, buah, dan minuman pendamping, serta kesesuaian pola tersebut dengan kelompok penerima. Pendekatan berbasis data diperlukan agar catatan distribusi yang semula bersifat administratif dapat diubah menjadi informasi untuk mendukung perencanaan dan pengendalian program [1],[2].

Data menu MBG memiliki karakteristik transaksional karena satu kejadian distribusi memuat beberapa item yang diberikan secara bersamaan. Karakteristik tersebut sesuai dengan association rule mining (ARM), yaitu teknik data mining untuk menemukan item yang sering muncul bersama dan membentuk aturan implikatif $A \rightarrow B$. ARM tidak dimaksudkan untuk membuktikan hubungan sebab-akibat, tetapi untuk menunjukkan keteraturan ko-kemunculan yang dapat menjadi petunjuk evaluasi. Ukuran support menggambarkan seberapa sering kombinasi terjadi, confidence menunjukkan konsistensi kemunculan konsekuen ketika anteseden muncul, sedangkan lift membandingkan kekuatan hubungan dengan peluang kemunculan secara independen [3].

Berbagai studi telah menggunakan Apriori pada data kesehatan dan pangan [4] memanfaatkan aturan asosiasi untuk mengidentifikasi kombinasi titik akupunktur pada kondisi klinis, menunjukkan bahwa frequent itemset dapat membantu mengungkap kombinasi yang berulang. Nurmalasari et al. menerapkan Apriori untuk melihat pola hubungan status gizi balita [5]. Sementara itu, Liu dan Gao menggunakan analisis komposisi pangan dan Apriori pada sistem rekomendasi nutrisi [6]. Temuan tersebut memperlihatkan relevansi association rule mining pada domain kesehatan dan konsumsi, tetapi sebagian besar penelitian masih berfokus pada pola individu, layanan klinis, penjualan, atau sistem rekomendasi. Evaluasi terstruktur terhadap kombinasi menu pada program pangan publik dan keterkaitannya dengan kelompok penerima masih relatif terbatas.

Kesenjangan penelitian tidak hanya terletak pada objek kajian, tetapi juga pada justifikasi algoritma. Apriori sering dipilih karena populer dan tersedia pada berbagai pustaka, namun pemilihan metode seharusnya mempertimbangkan karakteristik data. FP-Growth menghindari pembentukan kandidat melalui struktur FP-tree dan umumnya lebih efisien pada data besar atau pola yang padat [7]. Eclat menggunakan representasi vertikal transaction identifier set dan operasi irisan untuk menelusuri itemset secara depth-first [8]. Kedua metode tersebut dapat menurunkan biaya pemindaian basis data

pada skenario tertentu. Sebaliknya, Apriori melakukan pencarian bertingkat dari 1-itemset menuju k-itemset berdasarkan prinsip downward closure, sehingga setiap tahap dapat ditelusuri secara langsung [9].

Dalam penelitian ini, Apriori dipilih bukan karena selalu paling cepat, melainkan karena dataset yang dianalisis berukuran kecil, jumlah item menu terbatas, dan tujuan penelitian bersifat eksploratif serta menekankan transparansi interpretasi. Proses kandidat bertingkat memudahkan peneliti menunjukkan bagaimana item tunggal berkembang menjadi kombinasi dua atau lebih item, bagaimana kandidat dieliminasi oleh minimum support, dan bagaimana aturan dipilih berdasarkan confidence serta lift. Karakteristik tersebut penting dalam konteks evaluasi program publik yang membutuhkan hasil mudah diaudit oleh pengelola nonteknis. Keterbatasan Apriori berupa pemindaian berulang dan ledakan kandidat tetap diakui; karena itu, FP-Growth dan Eclat ditempatkan sebagai pembanding yang perlu diuji ketika ukuran data MBG meningkat.

Tabel 1. Perbandingan karakteristik algoritma frequent pattern mining

Algoritma	Strategi utama	Keunggulan	Keterbatasan dan alasan pemilihan
Apriori	Pencarian level-wise dan pembentukan kandidat	Transparan, mudah ditelusuri, aturan mudah diaudit	Pemindaian berulang dan kandidat dapat membesar; dipilih karena data kecil dan tujuan eksploratif
FP-Growth	Kompresi transaksi dalam FP-tree dan pattern growth	Menghindari pembentukan kandidat; efisien pada data besar/padat	Struktur pohon lebih kompleks untuk dijelaskan dan belum diperlukan pada lima transaksi
Eclat	Representasi vertikal TID-set dan irisan depth-first	Cepat pada sejumlah data transaksional dan mengurangi pemindaian horizontal	TID-set dapat membesar; proses kurang intuitif bagi evaluasi nonteknis

Berdasarkan kesenjangan tersebut, penelitian ini bertujuan: (1) membentuk frequent itemset dari transaksi menu MBG; (2) menghasilkan dan mengevaluasi aturan asosiasi menggunakan support, confidence, dan lift; (3) menyajikan hubungan antaritem melalui scatter plot dan network graph; serta (4) menjelaskan implikasi dan keterbatasan penggunaan Apriori pada data program pangan. Kontribusi penelitian terletak pada penyajian analisis yang transparan, penambahan justifikasi komparatif terhadap FP-Growth dan Eclat, serta interpretasi aturan yang lebih hati-hati agar hasil tidak disamakan dengan hubungan kausal atau signifikansi statistik.

2. Metode Penelitian

2.1 Desain Penelitian dan Sumber Data


Penelitian menggunakan desain kuantitatif eksploratif dengan pendekatan data mining. Dataset yang tersedia merupakan data sekunder berupa rekapitulasi contoh transaksi distribusi menu MBG yang terdapat pada naskah penelitian. Satu transaksi merepresentasikan satu paket atau kejadian distribusi yang memuat kombinasi makanan dan kelompok penerima. Dataset terdiri atas lima transaksi (T1-T5), sehingga analisis diposisikan sebagai demonstrasi metodologis dan eksplorasi pola, bukan sebagai estimasi keadaan program MBG secara nasional.

Item yang dianalisis mencakup makanan pokok (nasi), lauk protein (ayam, ikan, telur), sayuran (sayur hijau dan sayur kuning), menu pendamping (buah dan susu), serta kelompok penerima (SD dan SMP). Identitas personal tidak digunakan. Kriteria inklusi adalah transaksi yang memiliki sekurang-kurangnya satu item makanan pokok, satu komponen pendamping, dan informasi kelompok penerima. Penulisan item diseragamkan agar variasi huruf, spasi, atau sinonim tidak menghasilkan item yang berbeda secara komputasional. Karena sumber data bersifat sekunder dan berukuran sangat terbatas, hasil harus dibaca sebagai proof of concept.

2.2 Kerangka Kerja Knowledge Discovery in Database

Kerangka kerja mengikuti Knowledge Discovery in Database (KDD), yaitu proses sistematis untuk mengubah data menjadi pengetahuan yang dapat diinterpretasikan [4]. Tahapan penelitian meliputi:

1. Seleksi data. Atribut dipilih berdasarkan relevansinya terhadap pola menu, yaitu item makanan dan kelompok penerima. Informasi administratif yang tidak berkontribusi terhadap pembentukan itemset tidak disertakan.
2. Prapemrosesan. Data diperiksa untuk menemukan duplikasi, nilai kosong, dan perbedaan penamaan item. Tahap ini mencegah satu bahan makanan terbaca sebagai beberapa kategori.
3. Transformasi. Setiap transaksi diubah menjadi matriks biner. Nilai 1 menunjukkan item terdapat dalam transaksi, sedangkan nilai 0 menunjukkan item tidak terdapat dalam transaksi.
4. Data mining. Algoritma Apriori membentuk frequent itemset berdasarkan minimum support. Itemset yang memenuhi ambang kemudian digunakan untuk menghasilkan aturan asosiasi.
5. Evaluasi dan interpretasi. Aturan dinilai menggunakan support, confidence, dan lift. Aturan redundan disaring agar pembahasan berfokus pada pola yang paling representatif.
6. Visualisasi. Scatter plot digunakan untuk melihat posisi aturan berdasarkan support dan confidence, sedangkan network graph menunjukkan arah hubungan antaritem.



Gambar 1. Alur penelitian berbasis kerangka KDD

2.3 Mekanisme Algoritma Apriori

Apriori memanfaatkan prinsip bahwa setiap subset dari itemset yang frequent juga harus frequent. Proses dimulai dengan menghitung support seluruh 1-itemset. Item yang memenuhi minimum support digabungkan untuk membentuk kandidat 2-itemset. Kandidat yang memiliki subset tidak frequent dieliminasi sebelum support dihitung. Proses yang sama dilanjutkan menuju k-itemset hingga tidak ada kandidat baru yang memenuhi ambang [9]. Mekanisme ini menghasilkan proses yang mudah diaudit, tetapi jumlah kandidat dapat tumbuh cepat ketika jumlah item dan transaksi meningkat.

Misalkan D merupakan kumpulan transaksi dengan jumlah N, A adalah anteseden, dan B adalah konsekuen. Nilai support aturan $A \rightarrow B$ dihitung dari proporsi transaksi yang memuat A dan B secara bersamaan:

$$\text{Support}(A \rightarrow B) = \text{Frekuensi}(A \cup B) / N \quad (1)$$

Confidence mengukur probabilitas kemunculan B ketika A telah muncul. Nilai ini diperoleh dengan membandingkan support gabungan A dan B terhadap support A:

$$\begin{aligned} \text{Confidence}(A \rightarrow B) \\ = \text{Support}(A \cup B) / \text{Support}(A) \end{aligned} \quad (2)$$

Lift membandingkan confidence aturan dengan peluang kemunculan B. Bentuk ekuivalennya dapat dituliskan sebagai berikut:

$$\text{Lift}(A \rightarrow B) = \frac{\text{Support}(A \cup B)}{(\text{Support}(A) \times \text{Support}(B))} \quad (3)$$

Lift > 1 menunjukkan asosiasi positif, lift = 1 menunjukkan kemunculan A dan B setara dengan kondisi independen, sedangkan lift < 1 menunjukkan asosiasi negatif. Nilai lift tidak otomatis menyatakan signifikansi statistik, terlebih pada dataset kecil. Oleh karena itu, interpretasi aturan dalam penelitian ini selalu mempertimbangkan jumlah transaksi, nilai support, dan konteks menu.

2.4 Parameter dan Penyaringan Aturan

Minimum support ditetapkan sebesar 40%. Pada lima transaksi, ambang tersebut berarti suatu itemset harus muncul sedikitnya dua kali agar dipertahankan. Minimum confidence ditetapkan sebesar 60% untuk memastikan bahwa konsekuensi muncul pada sekurang-kurangnya tiga dari lima peluang secara proporsional atau pada dua dari tiga kejadian, tergantung frekuensi antededen. Penetapan ambang dilakukan untuk menyeimbangkan jumlah keluaran dan keterbacaan hasil. Ambang support yang lebih rendah menghasilkan banyak pola dengan kemunculan tunggal, sedangkan ambang yang terlalu tinggi menyisakan pola umum yang kurang diskriminatif.

Aturan yang lolos minimum confidence selanjutnya diurutkan berdasarkan lift, confidence, dan support. Untuk tabel pembahasan, dipilih aturan representatif dengan konsekuensi tunggal, tidak sepenuhnya berulang, dan memiliki makna operasional. Aturan yang memuat nasi sebagai konsekuensi cenderung memiliki confidence 1,00 karena nasi terdapat pada seluruh transaksi; aturan tersebut tidak diprioritaskan sebab lift-nya umumnya 1,00 dan tidak menambah informasi diskriminatif.

2.5 Perangkat Analisis

Pengolahan dilakukan pada lingkungan Python. Pustaka pandas digunakan untuk pengelolaan data tabular [10], sedangkan mlxtend digunakan untuk transformasi transaksi, pembentukan frequent itemset, dan aturan asosiasi [11]. Matplotlib digunakan untuk scatter plot [12], dan NetworkX digunakan untuk visualisasi hubungan berbentuk jaringan. Naskah tidak menampilkan potongan kode program karena fokus penelitian terletak pada metode, hasil, dan interpretasi; kode hanya berfungsi sebagai instrumen komputasi yang mendukung reproduktibilitas.

3. Hasil dan Pembahasan

3.1 Karakteristik Dataset Transaksi

Dataset terdiri atas lima transaksi dengan sebelas kategori item. Setiap transaksi memuat nasi, satu sumber protein, satu jenis sayur, buah atau susu, serta kelompok penerima. Struktur transaksi ditunjukkan pada Tabel 2. Keberadaan nasi pada seluruh transaksi perlu dicatat

sejak awal karena item yang selalu muncul dapat menghasilkan confidence tinggi sebagai konsekuensi, tetapi lift mendekati atau sama dengan 1,00.

Tabel 2. Dataset transaksi Program MBG

ID	Itemset
T1	{Nasi, Ayam, Sayur Hijau, Susu, SD}
T2	{Nasi, Ikan, Sayur Hijau, Buah, SD}
T3	{Nasi, Ayam, Sayur Hijau, Buah, SMP}
T4	{Nasi, Telur, Sayur Hijau, Susu, SD}
T5	{Nasi, Ikan, Sayur Kuning, Buah, SMP}

Frekuensi item tunggal memperlihatkan bahwa nasi memiliki support 1,00, diikuti sayur hijau 0,80. Buah dan kelompok SD masing-masing memiliki support 0,60. Ayam, ikan, susu, dan kelompok SMP memiliki support 0,40 sehingga masih memenuhi minimum support. Telur dan sayur kuning hanya muncul satu kali atau memiliki support 0,20, sehingga tidak menjadi frequent 1-itemset pada ambang 40%.

Tabel 3. Frekuensi dan support item tunggal

Item	Frekuensi	Support
Nasi	5	1,00
Sayur Hijau	4	0,80
Buah	3	0,60
SD	3	0,60
Ayam	2	0,40
Ikan	2	0,40
Susu	2	0,40
SMP	2	0,40
Telur	1	0,20
Sayur Kuning	1	0,20

3.2 Frequent Itemset yang Dihasilkan

Dengan minimum support 0,40, proses Apriori menghasilkan 31 frequent itemset yang mencakup item tunggal dan kombinasi beberapa item. Jumlah tersebut menunjukkan bahwa sebagian besar kombinasi penting muncul sekurang-kurangnya pada dua transaksi. Itemset {Nasi, Sayur Hijau} memiliki support 0,80 dan menjadi kombinasi dua item paling dominan. Kombinasi {Nasi, SD}, {Nasi, Buah}, {SD, Sayur Hijau}, serta {Nasi, SD, Sayur Hijau} memiliki support 0,60.

Tabel 4. Frequent itemset representatif pada minimum support 40%

No	Frequent itemset	Frekuensi	Support
1	{Nasi}	5	1,00
2	{Sayur Hijau}	4	0,80
3	{Nasi, Sayur Hijau}	4	0,80
4	{Buah}	3	0,60
5	{SD}	3	0,60
6	{Nasi, Buah}	3	0,60
7	{Nasi, SD}	3	0,60
8	{SD, Sayur Hijau}	3	0,60
9	{Nasi, SD, Sayur Hijau}	3	0,60
10	{Ayam, Sayur Hijau}	2	0,40
11	{Buah, Ikan}	2	0,40
12	{Buah, SMP}	2	0,40
13	{Sayur Hijau, Susu}	2	0,40
14	{Nasi, SD, Sayur Hijau, Susu}	2	0,40

Kombinasi yang melibatkan nasi perlu diinterpretasikan secara hati-hati. Support tinggi pada {Nasi, Sayur Hijau} memang menunjukkan bahwa pasangan tersebut dominan, tetapi dominasi nasi sebagai item universal dapat mendorong banyak kombinasi berbasis nasi menjadi frequent. Sebaliknya, itemset {Buah, Ikan}, {Buah, SMP}, dan {Sayur Hijau, Susu} memiliki support 0,40 tetapi lebih diskriminatif karena hanya muncul pada subkelompok transaksi tertentu. Frequent itemset dengan support tinggi berguna untuk melihat menu inti, sedangkan itemset dengan support minimum dapat mengungkap variasi yang masih berulang dan layak diperiksa.

3.3 Aturan Asosiasi dan Interpretasi

Pembentukan aturan dengan minimum confidence 0,60 menghasilkan 67 aturan sebelum penyaringan redundansi. Banyak aturan merupakan variasi dari itemset yang sama, misalnya penambahan nasi pada anteseden atau konsekuen. Agar hasil lebih ringkas, Tabel 5 menampilkan sepuluh aturan representatif. Kode R1-R10 digunakan sebagai label pada scatter plot.

Tabel 5. Aturan asosiasi representatif

Kode	Aturan	Support	Confidence	Lift
R1	Ikan → Buah	0,40	1,00	1,67
R2	SMP → Buah	0,40	1,00	1,67
R3	Susu → SD	0,40	1,00	1,67
R4	Buah → Ikan	0,40	0,67	1,67
R5	Buah → SMP	0,40	0,67	1,67
R6	SD → Susu	0,40	0,67	1,67
R7	SD → Sayur Hijau	0,60	1,00	1,25
R8	Ayam → Sayur Hijau	0,40	1,00	1,25
R9	Sayur Hijau → SD	0,60	0,75	1,25
R10	Nasi → Sayur Hijau	0,80	0,80	1,00

R1 menunjukkan bahwa seluruh transaksi yang memuat ikan juga memuat buah. Support 0,40 berarti kombinasi tersebut muncul pada dua dari lima transaksi, confidence 1,00 menunjukkan konsistensi penuh pada data yang tersedia, dan lift 1,67 menunjukkan bahwa peluang buah ketika ikan muncul lebih tinggi daripada peluang dasar buah. Namun, dua kejadian belum cukup untuk menyatakan pola berlaku pada populasi MBG yang lebih luas. Aturan ini lebih tepat dipandang sebagai indikasi bahwa menu ikan pada dataset contoh cenderung dipasangkan dengan buah.


R2 memperlihatkan bahwa seluruh transaksi kelompok SMP pada dataset memuat buah. Lift 1,67 menunjukkan asosiasi positif, tetapi pola tersebut hanya berasal dari dua transaksi SMP. R3 menunjukkan hubungan Susu → SD dengan confidence 1,00 dan lift 1,67. Artinya, seluruh kemunculan susu terdapat pada transaksi kelompok SD, bukan bahwa susu harus selalu diberikan kepada SD. Arah aturan penting diperhatikan: confidence Susu → SD sebesar 1,00, sedangkan SD → Susu hanya 0,67 karena tidak semua transaksi SD memuat susu.

R7 dan R9 membentuk hubungan dua arah antara SD dan sayur hijau. Semua transaksi SD memuat sayur hijau sehingga confidence SD → Sayur Hijau mencapai 1,00. Sebaliknya, 75% transaksi yang memuat sayur hijau merupakan kelompok SD. Lift 1,25 pada kedua arah menunjukkan asosiasi positif yang lebih kuat dibandingkan kemunculan independen. R8 menunjukkan bahwa ayam selalu muncul bersama sayur hijau pada dua transaksi ayam. Pola ini dapat menjadi masukan untuk menilai konsistensi pasangan lauk dan sayur, tetapi belum dapat digunakan untuk menilai kecukupan gizi karena dataset tidak memuat berat porsi, kandungan zat gizi, atau tingkat konsumsi aktual.

R10 memiliki support tertinggi sebesar 0,80 sehingga pasangan nasi dan sayur hijau merupakan pola paling sering. Walaupun confidence mencapai 0,80, lift sebesar 1,00 menunjukkan bahwa kemunculan sayur hijau bersama nasi tidak lebih kuat daripada peluang dasar sayur hijau, karena nasi muncul pada semua transaksi. Temuan ini menegaskan bahwa confidence tinggi tidak selalu identik dengan aturan informatif. Penggunaan lift mencegah peneliti menyimpulkan asosiasi kuat hanya dari item yang sangat umum.

3.4 Visualisasi Aturan Asosiasi


Scatter plot pada Gambar 2 menempatkan support pada sumbu horizontal dan confidence pada sumbu vertikal, sedangkan ukuran titik merepresentasikan lift. Garis putus-putus menunjukkan ambang minimum support 0,40 dan confidence 0,60. R1-R3 berada pada confidence 1,00 dengan lift tertinggi, tetapi support-nya masih 0,40. R10 berada paling kanan karena memiliki support 0,80, namun ukuran titik lebih kecil akibat lift 1,00. Visualisasi ini membantu membedakan aturan yang sering muncul dari aturan yang memiliki asosiasi relatif kuat.



Gambar 2. Scatter plot support dan confidence; ukuran titik menunjukkan lift

Network graph pada Gambar 3 memvisualisasikan item sebagai simpul dan aturan sebagai panah. Ketebalan panah merepresentasikan support, sedangkan label sisi memuat confidence (c) dan lift (l). Sayur hijau menjadi simpul yang menerima hubungan

dari nasi, ayam, dan SD, sehingga berperan sebagai komponen sentral pada dataset. Buah menerima hubungan dari ikan dan SMP, sedangkan susu terhubung dengan SD. Dibandingkan tiga grafik batang terpisah, jaringan memberikan gambaran struktur hubungan yang lebih komprehensif dan menggunakan ruang secara lebih efisien.




Gambar 3. Network graph aturan asosiasi representatif

3.5 Analisis Sensitivitas Minimum Support

Pemilihan minimum support sangat memengaruhi banyaknya itemset dan aturan. Pengujian sensitivitas dilakukan dengan mempertahankan minimum confidence 0,60 dan mengubah minimum support menjadi 0,20; 0,40; 0,60; dan 0,80. Hasil pada Tabel 6 menunjukkan bahwa support 0,20 menghasilkan 111 frequent itemset dan 338 aturan. Sebagian besar pola tersebut berasal dari item yang hanya muncul satu kali, sehingga berisiko menimbulkan aturan tidak stabil. Pada support 0,80 hanya tersisa tiga itemset dan dua aturan, sehingga variasi menu hampir seluruhnya hilang.

Tabel 6. Sensitivitas jumlah keluaran terhadap minimum support

Minimum support	Frequent itemset	Aturan (confidence $\geq 0,60$)
0,20	111	338
0,40	31	67
0,60	9	14
0,80	3	2



Gambar 4. Perubahan jumlah frequent itemset dan aturan pada beberapa minimum support

Ambang 0,40 memberikan kompromi antara keluasan pola dan kemudahan interpretasi karena suatu itemset harus muncul minimal dua kali. Meskipun demikian,

ambang tersebut bukan nilai universal. Pada data operasional yang lebih besar, minimum support sebaiknya ditentukan melalui kombinasi pengetahuan domain, distribusi frekuensi item, analisis sensitivitas, serta tujuan keputusan. Item penting yang jarang muncul dapat dievaluasi dengan pendekatan multiple minimum support atau high-utility itemset mining agar tidak tersisih hanya karena frekuensinya rendah.

3.6 Implikasi terhadap Evaluasi Program MBG

Hasil association rule mining dapat mendukung evaluasi program pada tiga tingkat. Pertama, pola dengan support tinggi mengidentifikasi menu inti yang paling konsisten. Dalam data ini, nasi dan sayur hijau merupakan kombinasi dominan. Pengelola dapat menggunakan informasi tersebut untuk memeriksa apakah dominasi mencerminkan standar menu yang direncanakan atau justru menunjukkan variasi bahan pangan yang terbatas. Kedua, aturan dengan lift > 1 membantu menemukan pasangan yang lebih sering muncul daripada kondisi independen, seperti ikan dengan buah dan susu dengan kelompok SD. Pola tersebut dapat ditelusuri kembali ke jadwal menu, ketersediaan bahan, biaya, atau kebijakan kelompok sasaran.

Ketiga, aturan dapat digunakan sebagai mekanisme audit data. Jika suatu item seharusnya selalu dipasangkan dengan komponen tertentu berdasarkan standar menu, confidence yang rendah dapat menandai transaksi yang perlu diperiksa. Sebaliknya, confidence tinggi perlu dinilai bersama lift agar item umum tidak menghasilkan kesimpulan semu. Association rule mining sebaiknya ditempatkan sebagai alat pendukung, bukan pengganti penilaian ahli gizi. Keputusan perbaikan menu tetap memerlukan informasi berat porsi, energi, protein, lemak, vitamin, keamanan pangan, penerimaan peserta, dan biaya distribusi.

Tabel 7. Implikasi pola dan tindak lanjut yang disarankan

Temuan pola	Makna analitis	Tindak lanjut evaluasi
Nasi-Sayur Hijau dominan	Menu inti muncul pada mayoritas transaksi	Periksa variasi jenis sayur, porsi, dan rotasi menu
Ikan $\rightarrow$ Buah; lift 1,67	Pasangan lebih sering daripada peluang independen	Telusuri standar menu dan konsistensi pada periode lebih panjang
Susu $\rightarrow$ SD; lift 1,67	Susu hanya muncul pada kelompok SD dalam data contoh	Verifikasi kebijakan kelompok sasaran dan pemerataan menu
Nasi $\rightarrow$ Sayur Hijau; lift 1,00	Support tinggi tetapi hubungan netral	Hindari menyimpulkan asosiasi kuat hanya dari confidence
Aturan support 0,40	Pola didasarkan pada dua transaksi	Validasi dengan data lebih besar sebelum keputusan operasional

3.7 Perbandingan dengan Penelitian Terdahulu dan Keterbatasan

Temuan penelitian sejalan dengan studi terdahulu yang menunjukkan bahwa Apriori mampu mengubah catatan transaksional menjadi pola kombinasi yang mudah dijelaskan [9], [10], [11]. Perbedaannya, penelitian ini berfokus pada keterkaitan menu dan kelompok penerima dalam konteks program pangan publik serta menambahkan evaluasi lift, visualisasi jaringan, dan analisis sensitivitas ambang. Pendekatan tersebut memperluas pembahasan dari sekadar daftar aturan menuju penilaian apakah aturan benar-benar informatif dan bagaimana pola dapat ditindaklanjuti dalam evaluasi program.

Penelitian memiliki beberapa keterbatasan. Pertama, dataset hanya terdiri atas lima transaksi sekunder ilustratif sehingga support berubah sebesar 0,20 untuk setiap satu transaksi. Nilai confidence dan lift dapat berubah tajam ketika satu transaksi ditambahkan atau dihapus. Kedua, data tidak memuat periode, lokasi, berat porsi, kandungan gizi, sisa makanan, biaya, atau respons penerima. Ketiga, kelompok penerima hanya dibedakan menjadi SD dan SMP. Keempat, penelitian belum melakukan pengujian waktu komputasi dan penggunaan memori untuk membandingkan Apriori, FP-Growth, dan Eclat karena ukuran data terlalu kecil untuk menghasilkan perbandingan performa yang bermakna.

Penelitian lanjutan perlu menggunakan data transaksi nyata dalam periode panjang dan dari beberapa satuan pelayanan. Evaluasi dapat diperluas dengan membandingkan hasil itemset, waktu eksekusi, konsumsi memori, dan stabilitas aturan antara Apriori, FP-Growth, dan Eclat. Aturan juga dapat digabungkan dengan data kandungan gizi dan tingkat konsumsi agar analisis tidak hanya menilai ko-kemunculan menu, tetapi juga relevansinya terhadap kecukupan gizi. Validasi ahli gizi dan pengelola program diperlukan sebelum pola diterjemahkan menjadi kebijakan.

3.8 Verifikasi Perhitungan Manual

Validasi manual dilakukan untuk memastikan bahwa keluaran perangkat lunak konsisten dengan definisi matematis support, confidence, dan lift. Pada aturan R1, Ikan → Buah, item ikan muncul pada T2 dan T5. Kedua transaksi tersebut juga memuat buah. Dengan demikian, frekuensi gabungan {Ikan, Buah} adalah dua transaksi dari lima transaksi, sehingga support = $2/5 = 0,40$. Support ikan juga $2/5 = 0,40$, sehingga confidence = $0,40/0,40 = 1,00$. Karena support buah = $3/5 = 0,60$, nilai lift = $0,40/(0,40 \times 0,60) = 1,67$. Hasil tersebut sama dengan nilai pada Tabel 5.

Pada aturan R7, SD → Sayur Hijau, ketiga transaksi SD (T1, T2, dan T4) seluruhnya memuat sayur hijau. Support gabungan {SD, Sayur Hijau} = $3/5 = 0,60$ dan support SD = $3/5 = 0,60$, sehingga confidence = 1,00.

Support sayur hijau = $4/5 = 0,80$, sehingga lift = $0,60/(0,60 \times 0,80) = 1,25$. Artinya, pada data yang tersedia, peluang kemunculan sayur hijau ketika kelompok penerima adalah SD meningkat 25% dibandingkan peluang dasar sayur hijau.

Aturan R10, Nasi → Sayur Hijau, memberikan contoh penting tentang perbedaan support, confidence, dan lift. Gabungan nasi dan sayur hijau muncul pada empat dari lima transaksi sehingga support = 0,80. Karena nasi muncul pada seluruh transaksi, confidence = $0,80/1,00 = 0,80$. Namun, lift = $0,80/(1,00 \times 0,80) = 1,00$. Dengan demikian, aturan ini sangat sering muncul tetapi tidak menunjukkan ketergantungan relatif karena peluang sayur hijau ketika nasi muncul sama dengan peluang dasar sayur hijau.

Tabel 8. Verifikasi manual tiga aturan asosiasi

Aturan	Perhitungan support	Perhitungan confidence	Perhitungan lift
Ikan → Buah	$2/5 = 0,40$	$0,40/0,40 = 1,00$	$0,40/(0,40 \times 0,60) = 1,67$
SD → Sayur Hijau	$3/5 = 0,60$	$0,60/0,60 = 1,00$	$0,60/(0,60 \times 0,80) = 1,25$
Nasi → Sayur Hijau	$4/5 = 0,80$	$0,80/1,00 = 0,80$	$0,80/(1,00 \times 0,80) = 1,00$

Verifikasi manual juga menunjukkan bahwa perubahan satu transaksi dapat mengubah ukuran aturan secara nyata. Apabila satu transaksi ikan tidak memuat buah, support Ikan → Buah turun menjadi 0,20 dan aturan tidak lagi memenuhi minimum support 0,40. Karena itu, nilai yang tinggi pada dataset kecil tidak boleh diperlakukan sebagai bukti stabilitas. Pelaporan frekuensi absolut bersama nilai proporsional menjadi penting agar pembaca mengetahui dasar numerik setiap aturan.

3.9 Kualitas, Redundansi, dan Kelayakan Aturan

Jumlah aturan yang besar tidak selalu menunjukkan kualitas analisis yang lebih baik. Dari 67 aturan awal, sebagian merupakan aturan ekuivalen atau diperpanjang oleh item yang sangat umum. Sebagai contoh, Ikan → Buah dan {Ikan, Nasi} → Buah memiliki support, confidence, dan lift yang sama karena nasi muncul pada seluruh transaksi. Aturan dengan anteseden lebih pendek lebih disukai karena lebih sederhana dan tidak kehilangan informasi. Prinsip ini digunakan untuk mengurangi redundansi sebelum aturan dimasukkan ke dalam pembahasan.

Penyaringan juga mempertimbangkan arah hubungan. Ikan → Buah memiliki confidence 1,00, sedangkan Buah → Ikan hanya 0,67. Perbedaan tersebut terjadi karena semua ikan disertai buah, tetapi tidak semua buah disertai ikan. Oleh karena itu, association rule tidak bersifat simetris. Network graph menampilkan arah panah agar pembaca tidak menyamakan dua aturan yang berasal dari pasangan item yang sama.

Selain itu, lift diprioritaskan untuk membedakan aturan yang benar-benar menunjukkan peningkatan peluang dari aturan yang hanya mengikuti tingginya frekuensi item umum.

Tabel 9. Kriteria evaluasi kelayakan aturan

Kriteria	Pertanyaan evaluasi	Keputusan interpretasi
Support	Apakah pola muncul pada jumlah transaksi yang memadai?	Laporkan frekuensi absolut; hindari pola satu kali
Confidence	Seberapa konsisten konsekuensi muncul setelah anteseden?	Bandingkan kedua arah aturan
Lift	Apakah hubungan lebih kuat daripada peluang independen?	Prioritaskan lift > 1; lift = 1 bersifat netral
Nonredundansi	Apakah item tambahan mengubah metrik atau makna?	Pilih anteseden yang lebih pendek bila metrik sama
Actionability	Apakah pola dapat ditindaklanjuti oleh pengelola?	Hubungkan pola dengan rotasi menu dan audit distribusi
Kecukupan data	Apakah jumlah transaksi mendukung generalisasi?	Gunakan aturan kecil hanya sebagai indikasi eksploratif

Kelayakan aturan pada program MBG tidak hanya bergantung pada metrik komputasi. Aturan harus dapat diterjemahkan ke pertanyaan operasional, misalnya apakah pasangan lauk dan buah sesuai standar, apakah variasi menu antarkelompok seimbang, atau apakah terdapat item yang terlalu dominan. Aturan dengan lift tinggi tetapi support sangat rendah memerlukan verifikasi tambahan, sedangkan aturan dengan support tinggi dan lift netral lebih sesuai untuk menggambarkan menu inti daripada hubungan spesifik.

3.10 Rancangan Pengembangan pada Data Operasional

Penerapan pada data operasional memerlukan struktur data yang lebih lengkap daripada dataset contoh. Setiap transaksi idealnya memiliki identitas transaksi anonim, tanggal distribusi, satuan pelayanan, jenjang sekolah, jumlah penerima, daftar item, berat porsi, kandungan gizi, biaya, pemasok, sisa makanan, dan tingkat penerimaan. Struktur tersebut memungkinkan aturan asosiasi dianalisis menurut waktu, wilayah, kelompok umur, dan karakteristik menu. Data personal peserta tidak perlu dimasukkan ke dalam proses mining apabila tujuan analisis hanya mengevaluasi pola menu agregat.

Tabel 10. Elemen data yang disarankan untuk analisis MBG berskala operasional

Elemen data	Contoh isi	Fungsi analisis
ID transaksi dan tanggal	MBG-0001; 12-05-2026	Pelacakan dan analisis periode
Unit layanan/sekolah	SPPG A; SD X	Perbandingan lokasi dan kelompok
Item dan berat porsi	Nasi 150 g; ikan 60 g	Pola ko-kemunculan dan kuantitas
Kandungan gizi	Energi, protein, lemak, serat	Menghubungkan aturan dengan kecukupan gizi
Penerimaan dan sisa	Skor kesukaan; sisa 10%	Menilai pola menu yang diterima
Biaya dan pemasok	Rp15.000; pemasok B	Evaluasi efisiensi dan konsistensi pasokan

Ketika jumlah transaksi bertambah, pemilihan algoritma perlu diuji secara empiris. Apriori, FP-Growth, dan Eclat sebaiknya dijalankan pada dataset serta ambang yang sama. Perbandingan tidak hanya mencakup waktu eksekusi, tetapi juga penggunaan memori, jumlah frequent itemset, jumlah aturan, kesamaan pola, dan kemudahan audit. FP-Growth diperkirakan unggul ketika transaksi menjadi besar dan pola padat karena tidak membentuk kandidat secara eksplisit [7]. Eclat dapat efisien melalui irisan TID-set [8], sedangkan Apriori tetap unggul dari sisi keterbacaan proses pada kebutuhan audit kebijakan [9].

Stabilitas aturan perlu diuji menggunakan pembagian periode atau bootstrap transaksi. Aturan yang terus muncul pada beberapa bulan, sekolah, atau sampel ulang lebih layak diprioritaskan daripada aturan yang hanya muncul pada satu subset. Ukuran overlap seperti Jaccard dapat digunakan untuk membandingkan himpunan itemset antarperiode. Selain itu, aturan dapat dikelompokkan menjadi menu inti, pola kelompok penerima, pola musiman, dan anomali distribusi agar hasil lebih mudah digunakan pada dashboard pengelola.

Dalam implementasi, dashboard sebaiknya tidak hanya menampilkan daftar aturan. Pengguna perlu memperoleh filter periode dan lokasi, network graph, scatter plot, frekuensi absolut, serta tautan menuju transaksi pembentuk aturan. Dengan cara tersebut, pengelola dapat menelusuri kembali pola yang terlihat dan melakukan verifikasi terhadap jadwal menu atau dokumen distribusi. Pendekatan ini menjaga keterlacakan keputusan dan mencegah aturan asosiasi digunakan secara otomatis tanpa validasi ahli gizi dan konteks operasional.

3.11 Ancaman Validitas dan Strategi Mitigasi

Interpretasi hasil association rule mining perlu mempertimbangkan ancaman validitas. Validitas data dapat terganggu oleh kesalahan pencatatan menu, perbedaan istilah, transaksi ganda, atau item yang tidak dicatat secara konsisten. Sebagai contoh, “sayur hijau”, “sayuran hijau”, dan nama jenis sayur tertentu dapat diperlakukan sebagai item berbeda apabila proses standardisasi tidak dilakukan. Dampaknya adalah support terpecah dan pola yang sebenarnya dominan menjadi tidak terlihat. Mitigasi dilakukan melalui kamus item, pemeriksaan duplikasi, dan validasi silang dengan dokumen distribusi.

Validitas konstruk juga menjadi perhatian karena kemunculan item dalam transaksi tidak identik dengan konsumsi aktual atau kecukupan gizi. Aturan Ikan → Buah hanya menyatakan kedua item tercatat dalam paket yang sama; aturan tersebut tidak menjelaskan apakah seluruh porsi dikonsumsi, apakah kandungan gizi memenuhi standar, atau apakah penerima menyukai menu. Karena itu, hasil ARM perlu

dipadukan dengan data berat porsi, kandungan zat gizi, sisa makanan, dan penilaian penerimaan agar konstruk “menu bergizi” diukur secara lebih lengkap.

Validitas eksternal sangat terbatas karena penelitian menggunakan lima transaksi contoh. Pola yang ditemukan tidak dapat langsung diterapkan pada sekolah, wilayah, atau periode lain. Selain itu, ambang support 0,40 pada lima transaksi setara dengan dua kejadian, sehingga satu perubahan transaksi dapat mengubah status frequent dan non-frequent. Generalisasi baru dapat dipertimbangkan setelah pola diuji pada data multi-periode, multi-lokasi, dan jumlah transaksi yang memadai.

Validitas kesimpulan dipengaruhi oleh kecenderungan menghasilkan banyak aturan. Sebanyak 67 aturan pada data kecil meningkatkan risiko pembaca memilih aturan yang tampak menarik tanpa memperhatikan redundansi dan dasar frekuensinya. Lift > 1 juga bukan uji signifikansi statistik. Strategi mitigasi meliputi pelaporan frekuensi absolut, penyaringan aturan redundan, pembatasan aturan berdasarkan makna operasional, analisis sensitivitas ambang, serta validasi pada subset waktu atau lokasi yang berbeda.

Tabel 11. Ancaman validitas dan strategi mitigasi

Jenis validitas	Ancaman utama	Strategi mitigasi
Validitas data	Kesalahan pencatatan, sinonim item, dan duplikasi	Kamus item, pembersihan data, dan audit dokumen sumber
Validitas konstruk	Ko-kemunculan disamakan dengan konsumsi atau kecukupan gizi	Tambahkan berat porsi, kandungan gizi, penerimaan, dan sisa
Validitas eksternal	Lima transaksi tidak mewakili populasi MBG	Gunakan data multi-periode dan multi-lokasi
Validitas kesimpulan	Banyak aturan, redundansi, dan salah tafsir lift	Laporkan frekuensi, filter redundansi, dan uji stabilitas
Validitas algoritmik	Kinerja Apriori belum dibandingkan pada data besar	Bandingkan Apriori, FP-Growth, dan Eclat pada dataset sama

3.12 Reprodusibilitas dan Standar Pelaporan

Reprodusibilitas penting agar hasil dapat diperiksa kembali oleh peneliti atau pengelola program. Setiap analisis perlu menyimpan versi dataset, tanggal ekstraksi, aturan pembersihan, daftar item, nilai minimum support dan confidence, versi pustaka, serta kriteria penyaringan aturan. Perubahan kecil pada penamaan item atau parameter dapat menghasilkan frequent itemset yang berbeda, sehingga dokumentasi proses harus diperlakukan sebagai bagian dari hasil penelitian, bukan sekadar catatan teknis.

Kode program tidak perlu ditempatkan sebagai blok sintaks di dalam naskah utama. Praktik yang lebih tepat adalah menyimpan kode pada lampiran atau repositori pendukung, sementara artikel menjelaskan input, tahapan transformasi, fungsi algoritma, parameter, dan

keluaran secara konseptual. Pendekatan tersebut menjaga keterbacaan artikel sekaligus memungkinkan replikasi. Pada penelitian ini, validasi manual terhadap tiga aturan telah disajikan untuk menunjukkan konsistensi antara definisi matematis dan keluaran perangkat lunak.

Standar pelaporan association rule mining sebaiknya mencantumkan jumlah transaksi, jumlah item unik, distribusi frekuensi item, ambang minimum, jumlah frequent itemset, jumlah aturan awal, jumlah aturan setelah penyaringan, aturan representatif, serta keterbatasan data. Visualisasi harus dilengkapi penjelasan tentang makna sumbu, ukuran titik, arah panah, dan dasar pemilihan aturan yang ditampilkan. Dengan pelaporan tersebut, pembaca dapat menilai apakah hasil kuat secara numerik atau hanya terbentuk karena item yang sangat umum.

Tabel 12. Checklist reprodusibilitas analisis association rule mining

Komponen pelaporan	Informasi yang dicantumkan
Dataset	Sumber, periode, jumlah transaksi, jumlah item, dan versi data
Prapemrosesan	Aturan normalisasi istilah, penanganan data kosong, dan duplikasi
Parameter	Minimum support, minimum confidence, ukuran lift, dan alasan pemilihan
Keluaran	Jumlah itemset, jumlah aturan awal, filter redundansi, dan aturan terpilih
Perangkat	Lingkungan Python serta versi pandas, mlxtend, Matplotlib, dan NetworkX
Validasi	Perhitungan manual, analisis sensitivitas, dan pengujian stabilitas
Keterbatasan	Skala data, batas generalisasi, dan variabel yang belum tersedia

Pada skala operasional, hasil analisis sebaiknya disimpan dalam format yang dapat diaudit, misalnya tabel aturan dengan identitas transaksi pembentuknya. Penyimpanan tersebut memudahkan pengelola menelusuri alasan suatu pola muncul dan mencegah keputusan hanya berdasarkan visualisasi ringkas. Reprodusibilitas juga mendukung perbandingan antarperiode karena parameter dan prosedur dapat diterapkan secara konsisten pada data baru.

4. Kesimpulan

Penelitian menerapkan association rule mining menggunakan algoritma Apriori untuk mengeksplorasi pola menu Program Makan Bergizi Gratis. Dengan minimum support 40% dan minimum confidence 60%, diperoleh 31 frequent itemset dan 67 aturan sebelum penyaringan redundansi. Kombinasi nasi dan sayur hijau memiliki support tertinggi 0,80. Aturan Ikan → Buah, SMP → Buah, dan Susu → SD memiliki confidence 1,00 serta lift 1,67, sedangkan Nasi → Sayur Hijau memiliki lift 1,00 sehingga tidak menunjukkan penguatan hubungan di atas peluang independen.

Apriori dipilih karena ukuran data kecil, jumlah item terbatas, dan proses kandidat bertingkat mudah ditelusuri serta dijelaskan. FP-Growth dan Eclat berpotensi lebih efisien pada dataset besar, tetapi keunggulan tersebut belum relevan untuk lima transaksi. Scatter plot dan network graph menghasilkan visualisasi yang lebih representatif daripada grafik batang terpisah karena dapat menunjukkan posisi, arah, dan struktur hubungan antaritem secara bersamaan.

Hasil penelitian bersifat eksploratif dan belum dapat digeneralisasikan terhadap pelaksanaan MBG secara nasional. Temuan sebaiknya digunakan sebagai contoh kerangka analisis dan dasar pengembangan penelitian dengan data nyata yang lebih besar, multi-periode, serta dilengkapi informasi kuantitas dan kandungan gizi. Perbandingan langsung Apriori, FP-Growth, dan Eclat diperlukan pada penelitian berikutnya untuk menentukan algoritma yang paling sesuai dari sisi interpretabilitas, waktu komputasi, dan penggunaan memori.

SUMBER RUJUKAN

Referensi

- [1] WORLD HEALTH ORGANIZATION, *The State of Food Security and Nutrition in the World 2023: Urbanization, agrifood systems transformation and healthy diets across the rural–urban continuum*. 2023.
- [2] Food and Agriculture Organization, *Repurposing food and agricultural policies to make healthy diets more affordable*. 2022.
- [3] R. E. N. Rongcai, W. U. Guoxiong, and C. A. I. Ming, *Data Mining: Concepts and Techniques*. 2023.
- [4] P. H. Lu, C. C. Lai, L. Y. Chiu, I. H. Lin, C. C. Iou, and P. H. Lu, “An Apriori algorithm-based association rule analysis to identify acupoint combinations for treating uremic pruritus,” *Tzu Chi Med. J.*, vol. 36, no. 2, pp. 195–202, 2024, doi: 10.4103/tcmj.tcmj_217_23.
- [5] E. Nurmallasari, U. Aryanti, and T. T. Rachman, “Penerapan Data Mining Algoritma Apriori untuk Menemukan Pola Hubungan Status Gizi Balita,” *Intern. (Information Syst. Journal)*, vol. 6, no. 2, pp. 156–166, 2024, doi: 10.32627/internal.v6i2.885.
- [6] S. Liu and J. Gao, “Application of Food Nutrient Composition Analysis and Computer Algorithm in Nutrition Recommendation System,” vol. 1, no. Incoft, pp. 332–338, 2025, doi: 10.5220/0013541000004664.
- [7] J. Han, J. Pei, and Y. Yin, “Mining Frequent Patterns without Candidate Generation,” *SIGMOD 2000 - Proc. 2000 ACM SIGMOD Int. Conf. Manag. Data*, pp. 1–12, 2000, doi: 10.1145/342009.335372.
- [8] E.-H. (Sam) Han, G. Karypis, and V. Kumar, “Scalable Parallel Data Mining for Association Rules,” *IEEE Trans. Knowl. Data Eng.*, vol. 12, no. 3, pp. 337–352, May 2000, doi: 10.1109/69.846289.
- [9] R. Agrawal and R. Srikant, “Fast Algorithms for Mining Association Rules,” *Proc. 20th Int. Conf. Very Large Data Bases, {VLDB’94}*, pp. 487–499, 1994, [Online]. Available: citeseer.ist.psu.edu/agrawal94fast.html
- [10] J. D. Hunter, “Matplotlib: A 2D Graphics Environment,” *Comput. Sci. Eng.*, vol. 9, no. 3, pp. 90–95, 2007, doi: 10.1109/MCSE.2007.55.
- [11] W. McKinney, “Data Structures for Statistical Computing in Python,” *Proc. 9th Python Sci. Conf.*, vol. 1, no. SciPy, pp. 56–61, 2010, doi: 10.25080/majora-92bf1922-00a.
- [12] A. A. Hagberg, D. A. Schult, and P. J. Swart, “Exploring Network Structure, Dynamics, and Function using NetworkX,” *Proc. 7th Python Sci. Conf.*, no. SciPy, pp. 11–15, 2008, doi: 10.25080/tcwg9851.