



Penerapan Association Rule-Market Basket Analysis (AR-MBA) Dalam Menentukan Strategi Product Bundling: Studi Kasus Pada Minimarket AKPRIND MART

Agus Hindarto Wibowo^{1✉}, Kartinasari Ayuhikmatin Sekarjati², Irfan Mustofa³, Nafis Sinta Makhulina⁴, Rio Dewangga⁵

Program Studi Teknologi Industri, Program Pendidikan Vokasi, Institut Sains & Teknologi AKPRIND, Yogyakarta, Indonesia ^{(1),(2),(5)}

Jurusan Teknik Industri, Fakultas Teknologi Industri, Institut Sains & Teknologi AKPRIND, Yogyakarta, Indonesia ^{(3),(4)}

DOI: 10.31004/jutin.v7i1.24873

✉ Corresponding author:
[bagushind@akprind.ac.id]

Article Info

Abstrak

Kata kunci:
AR-MBA;
Association Rule;
Data Mining;
Market Basket Analysis

Data telah menjadi komponen yang paling berharga untuk diproses untuk memberikan informasi yang berguna di dunia modern teknologi yang berkembang pesat. Ketika datang ke analisis data yang lebih mendalam atau jelas, teknologi sangat berguna. Operasi pemerintah, sosial, dan komersial nyata menggunakan teknologi ini; dalam kasus bisnis, ini ditunjukkan oleh jumlah minimarket yang beroperasi di seluruh Indonesia. Akibatnya, persaingan komersial meningkat. Oleh karena itu, untuk bersaing, sebuah studi yang menggunakan data yang tersedia harus dilakukan. Metode Association Rule-Market Basket Analysis digunakan dalam penelitian ini untuk mengidentifikasi minat pembelian pelanggan. Menurut temuan penelitian ini, dua rule 60% (perlengkapan cuci dan bahan makanan) dan 62% (obat dan minuman botol) menunjukkan nilai confidence terbesar. Berdasarkan temuan ini, minimarket dapat memutuskan apa yang harus dilakukan dalam hal Product Bundling, pengaturan tata letak dan tugas lainnya.

Keywords:
AR-MBA;
Association Rule;
Data Mining;
Market Basket Analysis

Abstract

Data has become the most valuable component to be processed in order to provide usable information in the modern world of rapidly developing technology. When it comes to more in-depth or clear data analysis, technology is quite useful. Real governmental, social, and commercial operations use this technology; in the case of business, this is demonstrated by the quantity of minimarkets operating throughout Indonesia. As a result, it greatly increases commercial competition.

Consequently, in order to compete, a study using the available data must be conducted. The Association Rule-Market Basket Analysis method was employed in this study to ascertain the shopping interests of the participants. According to the study's findings, two rules 60% (washing equipment and foodstuffs) and 62% (medicine and bottled drinks) showed the greatest confidence values. Based on these findings, the minimarket can decide what has to be done in terms of Product Bundling, setting up the layout and other tasks.

1. PENDAHULUAN

Dalam era globalisasi dan persaingan bisnis yang semakin ketat saat ini, perusahaan harus memahami perilaku konsumen untuk mengoptimalkan strategi pemasaran mereka. Supermarket, sebagai salah satu bisnis yang berinteraksi langsung dengan pelanggan, sangat membutuhkan analisis pola pembelian pelanggan untuk meningkatkan operasi dan efisiensi. *Association Rule-Market Basket Analysis* (AR-MBA) adalah salah satu metode analisis yang telah berkembang menjadi alat yang efektif untuk mengungkap pola-pola tersebut. Berbagai aplikasi bisnis, seperti desain tata letak, desain katalog, strategi pemasaran, pengembangan orientasi bisnis, dll., dapat menggunakan metode ini (Larose, 2005) (Valle et al., 2018).

Metode data mining yang dikenal sebagai AR-MBA memungkinkan untuk mengidentifikasi hubungan dan asosiasi antara produk-produk yang dibeli oleh pelanggan secara bersamaan. Metode ini dapat membantu mengidentifikasi item apapun (sayur ataupun non sayur) yang sering terjadi bersamaan dalam transaksi untuk menentukan hubungan antara apa yang dibeli oleh pelanggan (Arianto & Nugroho, 2022). Pola ini memungkinkan supermarket untuk mengoptimalkan penataan produk, membuat rencana penawaran bundel yang lebih efisien, dan bahkan membuat program loyalitas pelanggan yang lebih unik.

Tujuan dari penelitian ini adalah untuk mempelajari bagaimana analisis AR-MBA dapat digunakan dalam konteks supermarket, dengan fokus pada pola pembelian konsumen. Diharapkan analisis ini akan menemukan hubungan yang kuat antara produk-produk tertentu, yang akan memungkinkan manajemen supermarket untuk membuat strategi pemasaran yang lebih cermat dan sesuai dengan kebutuhan konsumen.

Penelitian ini akan membahas konsep dasar dari AR-MBA, relevansinya dalam konteks supermarket, dan potensi dampak dari analisis ini terhadap peningkatan kinerja bisnis. Dengan memperdalam pemahaman kami tentang perilaku konsumen di supermarket, diharapkan penelitian ini dapat membantu membuat kebijakan pemasaran yang lebih efisien, meningkatkan daya saing, dan meningkatkan kepuasan konsumen (Wibowo et al., 2023).

Penelitian ini didasarkan untuk mengubah strategi pemasaran AKPRIND MART untuk menjadi lebih efektif, unggul, dan menyenangkan pelanggan. AKPRIND MART dipilih sebagai lokasi penelitian karena menghadapi tantangan dan peluang yang berbeda dalam industri ritel dan lokasi ini baru berdiri dan butuh sekali pengembangan. Metode Data Mining AR-MBA akan digunakan dalam penelitian ini untuk mendapatkan pemahaman yang mendalam. AKPRIND MART bekerja dalam industri ritel yang sangat dinamis dan menantang. Strategi pemasaran harus fleksibel dan kreatif karena persaingan yang ketat, pola pembelian yang berubah, dan gaya konsumen yang berubah. Kemudian metode Data Mining AR-MBA memungkinkan untuk menemukan pola-pola yang tersembunyi dalam data transaksi, memahami hubungan antar produk, dan menemukan keinginan pelanggan. Dengan demikian, AKPRIND MART dapat mengembangkan strategi pemasaran yang lebih tepat sasaran.

Analisis asosiasi yang dihasilkan oleh Data Mining AR-MBA memungkinkan AKPRIND MART untuk menemukan keterkaitan antar produk, membantu dalam menentukan *bundling* produk yang efektif, dan merancang promosi yang lebih cerdas. Hal ini akan memberikan keunggulan yang diperlukan untuk bersaing di pasar yang ketat. Penelitian ini, melalui pendekatan AR-MBA, akan membantu AKPRIND MART mengoptimalkan portofolio produk mereka. Dengan memahami bagaimana produk berinteraksi dengan pola pembelian, mereka dapat mengubah penempatan produk, stok, dan penawaran promosi untuk meningkatkan penjualan dan keuntungan. Implementasi Data Mining AR-MBA juga bertujuan untuk meningkatkan kepuasan pelanggan. AKPRIND MART dapat memberikan pengalaman belanja yang lebih personal dan memuaskan dengan memahami preferensi pelanggan secara lebih akurat. Dengan mengutamakan AKPRIND MART sebagai lokasi penelitian dan menggunakan metode Data Mining AR-MBA, penelitian ini diharapkan dapat menawarkan solusi praktis dan dapat diukur untuk mengoptimalkan kebijakan pemasaran, meningkatkan daya saing, dan memaksimalkan kepuasan pelanggan dalam lingkungan bisnis yang selalu berubah.

2. METODE PENELITIAN

2.1 Cross Industry Standard Process for Data Mining (CRISP-DM)

Selama proses penambangan data, CRISP-DM adalah metode standar yang membantu tim analisis data di setiap tahap proses, dari pemahaman bisnis hingga penerapan solusi (Peker & Kart, 2023).

Tujuan utama pertambangan *rule* asosiasi adalah untuk melihat kumpulan objek yang biasanya muncul bersama-sama dalam dataset yang diberikan. Metodologi ini, yang berorientasi tujuan dan matang, masih sering digunakan dalam proyek data mining karena penggunaan algoritma data machine learning mining. Pendekatan siklus hidup CRISP-DM terdiri dari enam tahap utama (Martinez-Plumed et al., 2021):

a. Business Understanding:

Fase ini mengutamakan pemahaman tentang tujuan bisnis dan masalah yang perlu diselesaikan. Tim data mining bekerja sama dengan pemangku kepentingan bisnis untuk membuat pertanyaan yang relevan dan menentukan alasan analisis data. Tujuan bisnis dalam studi ini adalah untuk mengetahui bagaimana pelanggan membeli barang, mengoptimalkan produk, dan membuat rencana penjualan dan promosi (Solano et al., 2021).

b. Data Understanding:

Pada titik ini, tim memperoleh pemahaman tentang data yang tersedia untuk analisis. Ini termasuk pengumpulan data, pemeriksaan kualitas data, dan memperoleh pemahaman tentang fitur dasar dataset yang akan digunakan. Studi ini menggunakan 105 transaksi data pengeluaran dari pelanggan yang berbelanja di minimarket.

c. Data Preparation:

Pada tahap ini, data diproses untuk memastikan siap untuk analisis. Beberapa tugas yang terlibat dalam proses ini termasuk integrasi data dari berbagai sumber, transformasi data, dan pembersihan data.

d. Modeling:


Tahap ini memiliki tujuan utama untuk membuat model deskriptif atau prediktif dengan menggunakan teknik penambangan data yang tepat. Di sini, beberapa strategi yang paling umum digunakan adalah pembuatan model, penilaian model, dan modifikasi kinerja model. Referensi sebelumnya telah membagi fungsi estimasi, prediksi, klasifikasi, cluster, dan asosiasi data mining. Model AR-MBA dan pendekatan FP-Growth digunakan dalam penelitian ini.

e. Evaluation:

Evaluasi model dilakukan untuk memastikan bahwa model yang dibuat memenuhi tujuan bisnis awal. Ini melibatkan mengevaluasi kinerja model dan menentukan apakah solusi yang dihasilkannya dapat diterapkan dalam praktik.

f. Deployment:

Fase ini mencakup penggunaan model atau solusi penambangan data dalam lingkungan produksi. Ini memastikan bahwa manfaat analisis data dapat dicapai dan mengintegrasikan solusi ke dalam proses bisnis.



Gambar 1. Model Proses CRISP-DM dalam data mining

2.2 Association Rule

Association Rule adalah teknik dalam data mining yang digunakan untuk mengidentifikasi hubungan atau asosiasi antara satu set item atau variabel dalam dataset. Teknik ini sering digunakan dalam konteks analisis keranjang belanja (*Market Basket Analysis*) dan seringkali diterapkan dalam domain ritel atau e-commerce. Dalam hal ini, fokus utama adalah untuk menemukan keterkaitan antara produk atau item yang dibeli bersama oleh pelanggan. Contoh penerapan *Association Rule* yang populer adalah melalui algoritma Apriori dan FP-Growth. Metode ini bekerja dengan mengidentifikasi item atau produk yang sering dibeli bersamaan, dan kemudian menghasilkan *rule* asosiasi berdasarkan tingkat dukungan (*support*), tingkat kepercayaan (*confidence*), dan *lift* (Kotu & Deshpande, 2015).

a. Support (Dukungan):

Menunjukkan seberapa sering suatu kombinasi item muncul dalam dataset. Semakin tinggi nilai dukungan, semakin umum kombinasi item tersebut.

Dalam data mining, nilai *support* merupakan salah satu metrik yang digunakan dalam analisis asosiasi (*association rule mining*) untuk mengukur seberapa sering suatu kombinasi dari item-item tertentu muncul dalam dataset. Nilai *support* menunjukkan frekuensi relatif dari sebuah *rule* asosiasi atau kombinasi item dalam dataset terhadap keseluruhan transaksi atau data yang diamati.

Nilai *support* berkisar antara 0 dan 1. Semakin tinggi nilai *support* suatu *rule*, semakin sering *rule* tersebut muncul dalam dataset. Nilai *support* yang tinggi menunjukkan bahwa *rule* atau kombinasi item tersebut memiliki frekuensi kemunculan yang signifikan dalam dataset, sehingga dapat dianggap sebagai *rule* atau item yang cukup penting (Pathan et al., 2019). Nilai *support* sering digunakan bersama dengan metrik lain seperti *confidence* (keyakinan) dan *lift* untuk mengidentifikasi *rule* asosiasi yang paling relevan dan signifikan dalam suatu dataset (Arianto & Nugroho, 2022).

$$\text{Support} = P(A \cap B) = \frac{\text{banyaknya transaksi yang mengandung } A \cap B}{\text{Total Transaksi}}$$

b. Confidence (Kepercayaan):

Mengukur seberapa sering *rule* asosiasi terbukti benar. Misalnya, jika pelanggan membeli A, seberapa besar peluang mereka juga membeli B. *Confidence* tinggi menunjukkan hubungan yang kuat antara dua item.

Dalam analisis *rule* asosiasi (*association rule mining*), nilai kepercayaan adalah salah satu metrik yang digunakan dalam data mining untuk mengukur seberapa kuat atau dapat diandalkan sebuah *rule* asosiasi. Nilai kepercayaan menunjukkan seberapa sering suatu *rule* asosiasi benar jika item atau kondisi pada sisi kiri *rule* sudah ada (Dağslani & Başar, 2022).

Nilai kepercayaan berkisar antara 0 dan 1; nilai yang paling tinggi menunjukkan bahwa setiap kali X muncul, Y juga muncul, dan nilai yang paling rendah menunjukkan bahwa tidak ada hubungan antara X dan Y. Nilai yang lebih tinggi menunjukkan bahwa *rule* asosiasi lebih dapat diandalkan. Nilai kepercayaan harus dilihat bersama dengan nilai *support*. *Rule* dengan nilai kepercayaan tinggi tetapi *support* rendah mungkin tidak signifikan secara keseluruhan. Oleh karena itu, kedua metrik ini seringkali dipertimbangkan dalam analisis asosiasi untuk menemukan *rule* yang paling relevan dan dapat diterapkan dalam konteks bisnis atau penelitian (Liu et al., 2022).

$$\text{Confidence} = P(B/A) = \frac{\text{Support } A \cap B}{P(A)}$$

c. Lift / Improvement Ratio:

Merupakan ukuran kekuatan hubungan antara dua item, dibandingkan dengan kejadian yang diharapkan secara acak. *Lift* yang lebih besar dari 1 menunjukkan bahwa hubungan antara dua item lebih kuat daripada yang diharapkan secara acak.

$$\text{lift} = \frac{\text{Support } (A \cap B)}{\text{Support } (A) * \text{Support } (B)}$$

Nilai *Lift* digambarkan sebagai berikut:

$Lift = 1$: Tidak ada peningkatan efek. Analisis *lift* membantu pengambil keputusan karena *rule* asosiasi tidak memberikan kontribusi tambahan terhadap prediksi, dan prediksi tetap sama dengan situasi tanpa *rule* asosiasi. *Lift* yang lebih besar dari satu adalah peningkatan positif, di mana *rule* asosiasi memberikan kontribusi positif terhadap prediksi, dan kondisi X meningkatkan kemungkinan terjadinya Y. *Lift* yang lebih rendah dari satu adalah peningkatan negatif, di mana *rule* asosiasi memberikan kontribusi negatif terhadap prediksi, dan kondisi X menurunkan kemungkinan Nilai *Lift* yang rendah mungkin menunjukkan bahwa *rule* tersebut tidak relevan atau bahkan tidak memiliki dampak yang signifikan dalam meningkatkan peluang kejadian Y, sementara nilai *Lift* yang tinggi menunjukkan bahwa *rule* tersebut memiliki dampak yang signifikan dalam meningkatkan peluang kejadian Y.

Contoh *rule* asosiasi yang dihasilkan dari analisis keranjang belanja mungkin seperti:

- Jika pelanggan membeli roti dan mentega, maka dengan *confidence* tertentu, mereka juga kemungkinan membeli selai.
- Atau, jika pelanggan membeli susu dengan *confidence* tinggi, maka mereka mungkin juga membeli telur.

Penerapan AR-MBA membantu perusahaan untuk memahami perilaku konsumen, mengoptimalkan penataan produk, meningkatkan strategi pemasaran, dan merancang program loyalitas yang lebih efektif.

2.3 Market Basket Analysis

Market Basket Analysis (MBA) adalah teknik analisis data yang digunakan dalam industri pemasaran dan bisnis untuk menemukan pola pembelian yang mungkin dilakukan oleh pelanggan secara bersamaan. Analisis keranjang belanja ini berguna untuk memahami hubungan antara barang atau jasa yang dibeli oleh pelanggan, sehingga dapat memberikan wawasan yang berharga bagi perusahaan (Arianto & Nugroho, 2022).

Metode ini awalnya dibuat untuk meningkatkan efisiensi penempatan produk di toko ritel, tetapi sekarang digunakan di banyak industri. MBA membantu bisnis untuk:

- Cross-Selling*: Mendefinisikan produk atau layanan yang sering dibeli bersamaan sehingga bisnis dapat meningkatkan penjualan dengan menawarkan produk tambahan kepada pelanggan yang membeli satu produk tertentu.
- Up-Selling*: Menawarkan barang atau layanan yang lebih mahal atau lebih canggih kepada konsumen berdasarkan cara mereka membeli barang atau layanan tersebut.
- Manajemen inventaris: Memahami hubungan antara produk untuk mengatur inventaris dengan lebih baik.
- Strategi Belanja: Pahami bagaimana harga produk memengaruhi pembelian produk lain dalam keranjang belanja Anda.
- Customer Segmentation*: Membantu strategi pemasaran yang lebih terfokus dengan membagi pelanggan berdasarkan kebiasaan pembelian mereka.

Proses MBA, algoritma data mining seperti algoritma asosiasi digunakan untuk menemukan hubungan atau keterkaitan antara item dalam transaksi pembelian. Contoh yang paling terkenal dari gagasan ini adalah "*Rule* Asosiasi" atau "*Rule* Asosiasi Apriori", yang menemukan hubungan antara item dalam dataset transaksi. "Jika pelanggan membeli kopi, maka kemungkinan besar mereka juga akan membeli gula" adalah contoh *rule* asosiasi yang sederhana (Valle et al., 2018). Dengan pemahaman semacam ini, bisnis dapat membuat strategi pemasaran yang lebih baik dan meningkatkan kepuasan pelanggan (Wibowo et al., 2023).

3. HASIL DAN PEMBAHASAN

Mengkategorikan setiap variabel atau setiap transaksi ke dalam departemen yang sesuai adalah langkah pertama yang dilakukan setelah mendapatkan data transaksi. Ada 11 (sebelas) departemen dalam penelitian ini, antara lain Makanan, Makanan Kemasan, Minuman Botol, Minuman Seduh, Bahan Makanan, Perlengkapan Mandi, Perlengkapan rumah tangga (RT), Perlengkapan Pribadi, Perlengkapan Cuci, Obat, dan Alat Tulis Kantor. Tabel 1 menunjukkan bagaimana departemen diklasifikasikan berdasarkan jenis barang yang dibeli.

Tabel 1. Klasifikasi departemen dan jenis barang yang dibeli

Departemen	Jenis barang yang dibeli
Dept 1	Makanan
Dept 2	Makanan Kemasan
Dept 3	Minuman Botol
Dept 4	Minuman Seduh
Dept 5	Bahan Makanan
Dept 6	Perlengkapan Mandi
Dept 7	Perlengkapan RT
Dept 8	Perlengkapan Pribadi
Dept 9	Perlengkapan Cuci
Dept 10	Obat
Dept 11	Alat Tulis Kantor

Selanjutnya, untuk setiap transaksi, setiap jenis barang yang dibeli diklasifikasikan ke dalam masing-masing departemen. Ini ditunjukkan dalam Tabel 2 dengan contoh transaksi dari 1 hingga 105 dan jenis barang yang diklasifikasikan ke dalam masing-masing departemen.

Tabel 2. Departemen pada setiap transaksi

No	Transaksi	Jenis Barang
1	Trans 1	Dept 3
2	Trans 2	Dept 3 Dept 2
3	Trans 3	Dept 3 Dept 4 Dept 2
4	Trans 4	Dept 11
5	Trans 5	Dept 2
6	Trans 6	Dept 4 Dept 3 Dept 10
7	Trans 7	Dept 5 Dept 5 Dept 9
8	Trans 8	Dept 3
9	Trans 9	Dept 4 Dept 2
10	Trans 10	Dept 3 Dept 2 Dept 2
...
105	Trans 105	Dept 1

Transformasi data jenis data agar siap adalah mengubah data kategori atau variabel yang ada ketika baru. Ia menunjukkan dalam bentuk numerik tabel 3. Namun, angka 1 melibatkan pembelian tertentu, dan angka 0 transaksi tersebut tidak melibatkan pembelian barang dari departemen tersebut.

adalah proses mengubah untuk dianalisis. Contohnya numerik menjadi data mengubah dari beberapa dibuat komposit variabel contoh perubahan variabel dalam transaksi 1-5 dalam menunjukkan transaksi yang barang dalam departemen menunjukkan bahwa

Tabel 3. Transformasi data

Trans/Dept	Dept 1	Dept 2	Dept 3	Dept 4	Dept 5	Dept 6	Dept 7	Dept 8	Dept 9	Dept 10	Dept 11
Trans 1	0	0	1	0	0	0	0	0	0	0	0
Trans 2	0	1	1	0	0	0	0	0	0	0	0
Trans 3	0	1	1	1	0	0	0	0	0	0	0
Trans 4	0	0	0	0	0	0	0	0	0	0	1
Trans 5	0	1	0	0	0	0	0	0	0	0	0
Trans 6	0	0	1	1	0	0	0	0	0	1	0
Trans 7	0	0	0	0	1	1	0	0	1	0	0
Trans 8	0	0	1	0	0	0	0	0	0	0	0
Trans 9	0	1	0	1	0	0	0	0	0	0	0
Trans 10	1	1	1	0	0	0	0	0	0	1	0
...
Trans 105	1	0	0	0	0	0	0	0	0	0	0

Pelanggan AKPRIND MART adalah subjek penelitian ini. Data transaksi dikumpulkan dengan menemukan dan menganalisis struktur pembelian pelanggan melalui aplikasi seperti Microsoft Excel dan Rapidminer. Berikut hasil yang didapatkan setelah diolah menggunakan bantuan *software* Rapidminer.

Tabel 4. Hasil pengolahan data

Rule	Premises	Conclusion	Support	Confidence	LaPlace	Gain	p-s	Lift	Conviction
1	Dept 1	Dept 3	0.057143	0.545455	0.956897	-0.15238	-7.26E-04	0.987461	0.984762
2	Dept 2	Dept 3	0.180952	0.575758	0.898551	-0.44762	0.007347	1.04232	1.055102
3	Dept 9	Dept 5	0.028571	0.6	0.981818	-0.06667	0.022676	4.846154	2.190476
4	Dept 10	Dept 3	0.047619	0.625	0.973451	-0.10476	0.005533	1.131466	1.193651

Association Rules

[Departemen 7] --> [Departemen 3] (confidence: 0.500)

[Departemen 8] --> [Departemen 3] (confidence: 0.500)

[Departemen 1] --> [Departemen 3] (confidence: 0.545)

[Departemen 2] --> [Departemen 3] (confidence: 0.576)

[Departemen 9] --> [Departemen 5] (confidence: 0.600)

[Departemen 10] --> [Departemen 3] (confidence: 0.625)

Dari hasil data yang diproses menggunakan Rapidminer dengan dukungan minimum 0,1 dan kepercayaan minimum 0,58, hasil dari 2 rule ditunjukkan dalam Tabel 4. Data di atas menunjukkan hasil bahwa rule 3 dan 4 adalah yang mendapatkan nilai kepercayaan terbesar dibandingkan dengan rule keseluruhan, menunjukkan bahwa departemen 9 sering dibeli bersamaan dengan departemen 5 (perlengkapan cuci dan bahan makanan) dan sebaliknya. Hal ini dapat dilihat dari nilai Support, rasio lift, dan confidence terbesar 0,028, 4,84 dan 60% yang menunjukkan jumlah departemen 9 dan 5 yang dibeli secara bersamaan dalam semua transaksi. Kemungkinan membeli departemen 9 dengan 5 lebih tinggi dari kemungkinan membeli departemennya 5 dengan 9, seperti yang ditunjukkan dari nilai kepercayaan (%), ketika kemungkinan pembelian departemen tersebut 9 dengan 5, lebih besar dari kemungkinan pembelannya departemen 5 dengan 9. Kemudian, departemen 10 sering dibeli bersamaan dengan departemen 3 (obat dan minuman botol). Ini ditunjukkan dari nilai dukungan terbesar pertama setelah nilai departemen dukungan 9 dan 5 yang diperoleh, Hal ini dapat dilihat dari nilai Support, rasio lift, dan confidence terbesar 0,047, 1,13 dan 62% yang menunjukkan jumlah departemen 10 dan 3 yang dibeli secara bersamaan dalam semua transaksi.

4. KESIMPULAN

Hasilnya menunjukkan bahwa dua rule memiliki nilai kepercayaan tertinggi, yang menunjukkan bahwa mereka adalah departemen yang terdiri dari barang yang dibeli lebih sering. Kombinasi rule 4 yang terdiri dari departemen 10 (obat) dan 3 (minuman botol) memiliki nilai dukungan tertinggi, dengan tingkat Support, rasio lift, dan confidence terbesar 0,047, 1,13 dan 62%, yang menunjukkan bahwa departemen 10 dan 3 dibeli secara bersamaan dalam transaksi keseluruhan. Beberapa aplikasi dapat menggunakan pengetahuan yang diperoleh dari rule, seperti katalog dengan menggabungkan produk yang sering dibeli dan meletakkannya di dekat katalog, memilih tata letak belanja di mana produk yang biasa dibeli sama-sama harus ditempatkan seberapa dekat mungkin, dan membuat kupon belanja dengan memberikan produk yang jarang dibeli sebagai bonus dari membeli produk yang sering dibeli.

5. UCAPAN TERIMA KASIH

Ucapan terimakasih diberikan kepada pihak Institut Sains & Teknologi AKPRIND Yogyakarta (IST AKPRIND) dan AKPRIND MART yang bersedia dan mendukung untuk menjadi tempat penelitian.

6. DAFTAR PUSTAKA

Arianto, S., & Nugroho, A. J. (2022). Association Rule-Market Basket Analisis (AR-MBA) Untuk Menganalisis Keputusan Dalam Pembelian Sayur. *Cakrawala Ilmiah*, 1(10). <http://bajangjournal.com/index.php/JCI>

Dağaslanı, H., & Başar, Ö. D. (2022). Association Rules Mining on Retail Data. *EKOIST Journal of Econometrics and Statistics*, 0(37), 199–211. <https://doi.org/10.26650/EKOIST.2022.37.1145052>

Kotu, V., & Deshpande, B. (2015). *Predictive analytics and data mining: concepts and practice with RapidMiner*.

Larose, D. T. (2005). *Discovering Knowledge in Data: An Introduction to Data Mining* (1st ed.). John Wiley & Sons.

- Liu, H., Shu, Q., Xiong, H., & Yang, Y. (2022). Data Classification Algorithm Based on Association Rules from the Perspective of Data Mining. *IEEE International Conference on Knowledge Engineering and Communication Systems, ICKES 2022*. <https://doi.org/10.1109/ICKECS56523.2022.10060274>
- Martinez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernandez-Orallo, J., Kull, M., Lachiche, N., Ramirez-Quintana, M. J., & Flach, P. (2021). CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, 33(8), 3048–3061. <https://doi.org/10.1109/TKDE.2019.2962680>
- Pathan, A. F., Palande, S., Shende, T., Patil, R., & Gutte, P. S. (2019, March 16). A STUDY ON MARKET BASKET ANALYSIS AND ASSOCIATION MINING. *Proceedings of National Conference on Machine Learning*.
- Peker, S., & Kart, Ö. (2023). Transactional data-based customer segmentation applying CRISP-DM methodology: A systematic review. *Journal of Data, Information and Management*, 5(1–2), 1–21. <https://doi.org/10.1007/s42488-023-00085-x>
- Solano, J. A., Lancheros Cuesta, D. J., Umaña Ibáñez, S. F., & Coronado-Hernández, J. R. (2021). Predictive models assessment based on CRISP-DM methodology for students performance in Colombia - Saber 11 Test. *Procedia Computer Science*, 198, 512–517. <https://doi.org/10.1016/j.procs.2021.12.278>
- Valle, M. A., Ruz, G. A., & Morrás, R. (2018). Market basket analysis: Complementing association rules with minimum spanning trees. *Expert Systems with Applications*, 97, 146–162. <https://doi.org/10.1016/J.ESWA.2017.12.028>
- Wibowo, A. H., Andivas, M., Harits, D., Windyatri, H., & Nugraha, D. S. (2023). A Pattern Analysis on Goods Purchase Relationship for Minimarket's Customers by Using Association Rule-Market Basket Analysis Method (AR-MBA). *Journal of Information Technology Ampera*, 4(3), 2774–2121. <https://doi.org/10.51519/journalita.v4i3.422>