

Analisis Pola Pembelian Konsumen di PT XYZ Menggunakan Market Basket Analysis

Dio Putra¹, Jito Armando², Aldi Mulia³, Aulia Agung Dermawan^{4*}

^{1,2,3,4} Departemen of Engineering Management, Institut Teknologi Batam

Email: pdio63120@gmail.com¹, masstoo20@gmail.com², muliaaldi6@gmail.com³,
agung@iteba.ac.id

Abstrak

*Penulis Koresponding

DOI: <http://dx.doi.org/10.35718/jinseng.v4i2.8482126>

Received June 2026;

Received in revised form June 2026;

Accepted July 2022;

Market Basket Analysis (MBA) merupakan pendekatan data mining yang digunakan untuk mengidentifikasi pola asosiasi antar produk dalam data transaksi. Pendekatan ini bermanfaat bagi perusahaan ritel dalam memahami perilaku pembelian konsumen serta merancang strategi pemasaran yang tepat sasaran. Penelitian ini bertujuan menganalisis pola pembelian konsumen di PT XYZ, perusahaan ritel kebutuhan rumah tangga dan makanan ringan, menggunakan algoritma *FP-Growth*. Data yang digunakan adalah *dataset* transaksi pelanggan PT XYZ sebanyak 1.200 transaksi pada periode Januari-Maret 2025. Algoritma *FP-Growth* diterapkan dengan minimum support 5% dan confidence 60%. Hasil analisis menunjukkan kombinasi produk dengan asosiasi kuat, seperti "Mie Instan" → "Saus Sachet" (support: 0,15; confidence: 0,82; lift: 1,35), dan "Minuman Botol" → "Snack Ringan" (support: 0,13; confidence: 0,79; lift: 1,31). Pola ini mengindikasikan dua skenario pembelian: rutin dan impulsif, yang dapat dimanfaatkan untuk strategi *cross-selling*, *bundling*, penempatan produk, dan promosi. Temuan ini memberikan dasar optimalisasi pengelolaan stok dan pengambilan keputusan berbasis data.

Kata kunci *Market Basket Analysis, FP-Growth, Pola Pembelian Konsumen, Data Mining, Aturan Asosiasi, Strategi Pemasaran*

Abstract

Market Basket Analysis (MBA) is a data mining approach used to identify association patterns between products in transaction data. This approach is useful for retail companies in understanding consumer purchasing behavior and designing targeted marketing strategies. This study aims to analyze consumer purchasing patterns at PT XYZ, a household and snack retail company, using the *FP-Growth* algorithm. The data consists of 1,200 customer transactions from January to March 2025. The *FP-Growth* algorithm was applied with a minimum support of 5% and a confidence level of 60%. The analysis results show product combinations with strong associations, such as "Instant Noodles" → "Sachet Sauce" (support: 0.15; confidence: 0.82; lift: 1.35), and "Bottled Drinks" → "Light Snacks" (support: 0.13; confidence: 0.79; lift: 1.31). These patterns indicate two purchasing scenarios: routine and impulsive, which can be utilized for *cross-selling*, *bundling*, product placement, and promotional strategies. These findings provide a basis for optimizing stock management and data-driven decision making.

Keywords: *Market Basket Analysis, FP-Growth, Consumer Purchasing Patterns, Data Mining, Association Rules, Marketing Strategy*

1. PENDAHULUAN

Era digital tidak hanya membawa persaingan, tetapi juga ledakan data transaksi. Di sinilah letak tantangan sekaligus peluang. Metode lama gagal menangkap kompleksitas perilaku konsumen modern (Chen et al., 1996). Kini, dibutuhkan pendekatan berbasis data yang cerdas dan lincah—yang mampu membawa perusahaan melampaui angka-angka, menuju pemahaman yang benar-benar mendalam.

Market Basket Analysis (MBA) hadir sebagai solusi dengan menawarkan pendekatan eksploratif terhadap hubungan antar produk dalam satu transaksi pembelian (Agrawal & Srikant, 1994). Melalui teknik ini, perusahaan dapat mengetahui produk yang sering dibeli bersamaan dan memanfaatkannya untuk strategi promosi silang, *bundling* produk, serta perencanaan display toko yang efektif (Berry & Linoff, 2004). MBA menjadi lebih relevan ketika dikombinasikan dengan algoritma *FP-Growth* yang mampu mengekstraksi pola frekuensi tanpa beban komputasi berlebih (Han et al., 2011; Tan et al., 2019).

Penelitian sebelumnya telah menerapkan MBA di sektor ritel. Hidayat (2020) menganalisis pola pembelian konsumen menggunakan algoritma Apriori dan menemukan asosiasi kuat pada produk kebutuhan pokok. Prasetyo & Utami (2018) mengimplementasikan *FP-Growth* di minimarket dan mengidentifikasi dominasi pola impulsif pada makanan ringan. Sudhakar & Ramakrishna (2021) menyimpulkan *FP-Growth* lebih efisien untuk *dataset* besar.

Namun, urgensi ini tidak diimbangi oleh kesiapan pelaku usaha. Penelitian ini dilakukan di PT XYZ, perusahaan ritel di Batam yang memiliki potensi besar menerapkan teknologi analitik data. Sayangnya, terjadi kesenjangan (*gap*) yang kritis: meskipun mengakumulasi kekayaan data transaksi harian, PT XYZ belum memanfaatkannya sama sekali untuk pengambilan keputusan strategis. Padahal, tanpa intervensi segera, perusahaan berisiko kehilangan peluang emas di tengah persaingan ritel yang semakin ketat. Penelitian ini bertujuan menggali wawasan strategis dari perilaku belanja konsumen yang tersembunyi dalam data. Kontribusi penelitian: (1) identifikasi pola asosiasi produk di konteks ritel Batam, (2) pemetaan dua skenario perilaku pembelian (rutin dan impulsif), serta (3) rekomendasi strategis berbasis data.

2. METODE

Penelitian ini menerapkan algoritma *FP-Growth* untuk mengekstraksi aturan asosiasi dari data transaksi PT XYZ menggunakan perangkat lunak Microsoft Excel dan RapidMiner.

A. Rancangan Penelitian

Penelitian ini dirancang sebagai studi kuantitatif eksploratif dengan pendekatan data mining. Fokus utama adalah pemanfaatan algoritma *FP-Growth* dalam *Market Basket Analysis* untuk mengungkap hubungan tersembunyi dalam perilaku pembelian konsumen. Pendekatan ini dipilih karena kemampuannya menganalisis data transaksi skala besar secara efisien (Han et al., 2011).

B. Sumber Data

Data bersumber dari sistem *Point of Sale* (POS) PT XYZ yang mencatat setiap transaksi di gerai. Dataset mencakup 1.200 transaksi unik periode Januari-Maret 2025 dengan 87 produk berbeda. Rata-rata produk per transaksi adalah 3-5 item. Data telah dianonimkan untuk menjaga kerahasiaan pelanggan (Rakesh & Srikant, 2000).

Tabel 1. Ringkasan Dataset Transaksi PT XYZ

No	Elemen Data	Deskripsi
1	Jumlah Transaksi	1.200 transaksi unik
2	Periode Waktu	Januari-Maret 2025
3	Jumlah Item Unik	87 produk berbeda

No	Elemen Data	Deskripsi
4	Rata-rata Produk/Transaksi	3-5 produk
5	Format Data	CSV (ekspor POS)

C. Algoritma *FP-Growth*

Algoritma *FP-Growth* bekerja dalam tiga tahap: (1) pemindaian pertama menghitung frekuensi item dan mengurutkannya, (2) pembangunan *FP-Tree* dengan memasukkan transaksi ke dalam pohon, (3) penambahan *FP-Tree* secara rekursif untuk menghasilkan *frequent itemset* (Han et al., 2011). Keunggulan *FP-Growth*: hanya dua kali pemindaian database, tidak membangkitkan kandidat itemset, dan efisien dalam memori (Zaki, 2000).

Sebagai ilustrasi, pada tahap (1) misalnya diperoleh frekuensi kemunculan item Mie Instan sebanyak 420 transaksi dan Sambal Sachet sebanyak 380 transaksi dari total 1.200 transaksi, sehingga kedua item diurutkan sebagai kandidat prioritas tinggi. Pada tahap (2), setiap transaksi yang memuat kedua item tersebut dipetakan menjadi satu jalur pada *FP-Tree*, dengan node yang sama digabungkan dan diberi bobot sesuai frekuensi kemunculan bersama. Pada tahap (3), penelusuran rekursif dari node *FP-Tree* menghasilkan kombinasi {Mie Instan, Sambal Sachet} sebagai salah satu *frequent itemset* yang selanjutnya diproses menjadi aturan asosiasi.

Parameter yang digunakan:

- Minimum *support*: 0,05 (5%)
- Minimum *confidence*: 0,6 (60%)
- Minimum *lift*: 1,0

Support menyatakan proporsi transaksi dalam dataset yang memuat kombinasi item tertentu secara bersamaan, sehingga mengindikasikan seberapa sering kombinasi tersebut muncul (Han et al., 2011). *Confidence* menunjukkan probabilitas bersyarat pembelian item konsekuen apabila item anteseden telah dibeli, yang mencerminkan kekuatan hubungan sebab-akibat antar produk (Tan et al., 2019). *Lift* mengukur seberapa kuat asosiasi antar item dibandingkan jika keduanya bersifat independen; nilai *lift* lebih dari 1,0 mengindikasikan asosiasi positif yang bermakna, bukan sekadar kebetulan statistik (Han et al., 2011). Threshold 5%, 60%, dan 1,0 dipilih untuk menyaring aturan asosiasi yang cukup sering muncul, cukup kuat prediksinya, dan benar-benar saling berasosiasi.

D. Teknik Analisis Data

Analisis data mencakup: (1) analisis frekuensi produk, (2) agregasi transaksi, (3) tabulasi silang, (4) identifikasi tren, (5) deteksi anomali, (6) pemetaan korelasi produk (Larose, 2015), dan (7) validasi hasil dengan pembagian data 80:20 (*training:testing*) (Witten et al., 2016).

E. Perangkat Lunak

Penelitian ini menggunakan dua perangkat lunak utama:

1. Microsoft Excel

Digunakan pada tahap awal untuk:

- Preprocessing data (pembersihan dan normalisasi data)
- Pivot table untuk analisis frekuensi produk
- Tabulasi silang (*cross-tabulation*) untuk melihat ko-eksistensi produk
- Visualisasi awal dan statistik deskriptif


2. RapidMiner Studio

Digunakan untuk analisis utama dengan alur kerja sebagai berikut:

- **Read Excel**: Mengimpor data yang telah dipreprocessing
- **FP-Growth**: Menerapkan algoritma *FP-Growth* untuk menemukan *frequent itemset*
- **Create Association Rules**: Membangkitkan aturan asosiasi dari *frequent itemset*
- **Filter Rules**: Menyaring aturan berdasarkan minimum support, confidence, dan lift
- **Generate Visualization**: Membuat visualisasi jaringan aturan asosiasi (Gambar 2)

RapidMiner dipilih karena:

- Antarmuka visual yang memudahkan pemahaman alur analisis
- Implementasi *FP-Growth* yang terintegrasi
- Kemampuan visualisasi jaringan yang informatif
- Tidak memerlukan pemrograman, sehingga dapat digunakan oleh praktisi bisnis



Gambar 1. Alur Kerja Analisis Market Basket Analysis Menggunakan RapidMiner

3. PEMBAHASAN

Penelitian menghasilkan dua skenario pola pembelian konsumen: (1) pola rutin dan (2) pola impulsif. Pembagian dua skenario ini didasarkan pada pola *support* dan *confidence* yang muncul secara empiris dari hasil FP-Growth, bukan pengelompokan yang ditetapkan sebelum analisis. Aturan asosiasi yang dihasilkan menunjukkan dua karakteristik jenis produk yang berbeda secara konsisten: kelompok pertama terdiri atas produk kebutuhan pokok (mi instan, minyak goreng, gula, beras) dengan *support* relatif tinggi dan stabil, mencerminkan pembelian terencana; kelompok kedua terdiri atas produk snack dan minuman (minuman botol, permen, kopi sachet) dengan *support* lebih rendah namun *confidence* dan *lift* tinggi, mencerminkan pembelian situasional. Pemisahan ini juga didukung oleh teori perilaku konsumen yang membedakan motif pembelian fungsional-terencana dan pembelian impulsif berbasis stimulus (Kotler & Keller, 2016; Berry & Linoff, 2004), sehingga kedua skenario merepresentasikan segmen perilaku yang secara konseptual maupun data memang berbeda.

A. Skenario 1: Pola Pembelian Rutin

Pola ini terjadi secara konsisten pada produk kebutuhan pokok dengan frekuensi tinggi.

Tabel 2. Aturan Asosiasi Pola Pembelian Rutin

No	Aturan Asosiasi	Support	Confidence	Lift
1	{Mie Instan} → {Sambal Sachet}	0,15	0,82	1,35
2	{Minyak Goreng} → {Gula}	0,11	0,74	1,22
3	{Beras} → {Minyak Goreng}	0,09	0,71	1,18

Aturan ini mencerminkan perilaku belanja terencana dengan produk pelengkap. Produk memiliki frekuensi stabil dan predictable demand, cocok untuk strategi *auto-replenishment*.

B. Skenario 2: Pola Pembelian Impulsif

Pola ini bersifat situasional, terjadi pada akhir pekan atau promosi tertentu.

Tabel 3. Aturan Asosiasi Pola Pembelian Impulsif

No	Aturan Asosiasi	Support	Confidence	Lift
1	{Minuman Botol} → {Snack Ringan}	0,13	0,79	1,31
2	{Permen} → {Tisu Basah}	0,08	0,72	1,25
3	{Kopi Sachet} → {Rokok}	0,06	0,65	1,18


Pola ini dipicu oleh posisi produk di dekat kasir atau promosi visual. Meskipun support lebih rendah, confidence dan lift cukup tinggi untuk strategi *impulse marketing*.

C. Perbandingan Kedua Skenario

Tabel 4. Perbandingan Karakteristik Skenario

Aspek	Pola Rutin	Pola Impulsif
Jenis Produk	Kebutuhan pokok	Snack, minuman
Frekuensi	Stabil	Fluktuatif
Prediktabilitas	Tinggi	Rendah
Strategi Promosi	Paket bulanan	Display kasir
Risiko Kehabisan Stok	Rendah	Tinggi
Penempatan Produk	Rak utama	End-rack/kasir

Validasi dengan data uji menunjukkan penurunan confidence rata-rata $<5\%$, mengindikasikan aturan stabil dan tidak *overfit* (Witten et al., 2016).



Gambar 2. Visualisasi Jaringan Aturan Asosiasi Produk di PT XYZ (Hasil RapidMiner)

Visualisasi jaringan dari RapidMiner ini menunjukkan hubungan antar produk berdasarkan aturan asosiasi yang dihasilkan dari analisis *FP-Growth*. Produk dengan asosiasi kuat terlihat saling terhubung dengan garis tebal, seperti:

- Mie Instan ↔ Sambal Sachet (confidence: 0,82)
- Minuman Botol ↔ Snack Ringan (confidence: 0,79)
- Minyak Goreng ↔ Gula (confidence: 0,74)

Pola ini mengkonfirmasi adanya dua klaster utama: klaster produk kebutuhan pokok (rutin) dan klaster produk impulsif. Visualisasi ini memudahkan manajemen PT XYZ dalam mengidentifikasi produk-produk yang sebaiknya ditempatkan berdekatan di rak toko.

D. Interpretasi Temuan Utama

Hasil penelitian mengungkap dua pola perilaku pembelian konsumen yang berbeda di PT XYZ. Pola pembelian rutin dengan confidence 82% pada aturan asosiasi Mie Instan menuju Sambal Sachet mencerminkan perilaku konsumen rasional dan terencana. Konsumen dalam kategori ini cenderung telah menentukan daftar belanja sebelum memasuki toko. Temuan ini sejalan dengan teori perilaku konsumen Kotler & Keller (2016) yang menyatakan pembelian produk kebutuhan pokok didorong oleh motif fungsional dan utilitarian.

Pola pembelian impulsif dengan confidence 79% pada aturan asosiasi Minuman Botol menuju Snack Ringan menunjukkan bahwa terdapat segmen konsumen yang responsif terhadap rangsangan pemasaran visual dan kontekstual. Pembelian impulsif ini terjadi tanpa perencanaan sebelumnya dan dipicu oleh penempatan produk, promosi harga, atau suasana toko (Berry & Linoff, 2004). Temuan ini memperkuat penelitian Prasetyo & Utami (2018) yang menemukan produk makanan ringan dan minuman memiliki tingkat pembelian impulsif tinggi.

Tingginya confidence pada kedua skenario menunjukkan bahwa konsumen telah membentuk kebiasaan pembelian (*purchase habit*) terhadap produk-produk tertentu yang saling melengkapi. Kebiasaan ini terbentuk melalui pengalaman berulang dan kepuasan yang diperoleh dari kombinasi produk tersebut (Tan et al., 2019).

E. Perbandingan dengan Penelitian Sebelumnya

Tabel 5. Perbandingan dengan Penelitian Sebelumnya

Aspek	Penelitian Ini	Hidayat (2020)	Prasetyo & Utami (2018)	Sudhakar & Ramakrishna (2021)
Algoritma	FP- Growth	Apriori	FP-Growth	Apriori & FP- Growth
Lokasi	Batam	Tidak disebutkan	Perkotaan	India
Support tertinggi	0,15	0,12	0,18	0,10
Confidence tertinggi	0,82	0,78	0,85	0,75

Penelitian ini mendukung temuan Hidayat (2020) bahwa produk kebutuhan pokok memiliki asosiasi kuat dengan produk pelengkap. Namun, penelitian ini lebih komprehensif karena mengidentifikasi dua skenario pembelian berbeda, memberikan wawasan lebih kaya untuk pengambilan keputusan bisnis.

Berbeda dengan Sudhakar & Ramakrishna (2021) yang membandingkan performa Apriori dan *FP-Growth* di India, penelitian ini fokus pada penerapan *FP-Growth* di konteks ritel Indonesia dan menghasilkan temuan spesifik yang relevan dengan karakteristik pasar lokal. Perbedaan dengan Prasetyo & Utami (2018) yang menemukan dominasi makanan ringan dalam pola impulsif, kemungkinan disebabkan karakteristik konsumen Batam yang mayoritas karyawan industri dengan pola belanja lebih terencana dan iklim tropis yang meningkatkan permintaan minuman.

F. Implikasi Teoritis

Secara teoritis, penelitian ini memberikan kontribusi pada pengembangan teori perilaku konsumen di era digital, khususnya dalam konteks ritel tradisional yang mulai mengadopsi teknologi analitik data (Laudon & Traver, 2020). Temuan dua skenario pembelian (rutin dan impulsif) memperkaya pemahaman tentang kompleksitas perilaku konsumen yang tidak dapat dijelaskan hanya dengan satu pendekatan tunggal (Tan et al., 2013).

Penelitian ini memperkuat teori tentang peran konteks dalam pembentukan pola pembelian (Larose, 2015). Faktor lokasi toko, musim, dan promosi terbukti mempengaruhi pola asosiasi produk. Hal ini

menunjukkan analisis data transaksi tidak dapat dilepaskan dari pemahaman kontekstual mendalam tentang operasional bisnis dan karakteristik pasar (Purba, 2021).

G. Implikasi Praktis dan Manajerial

1. Strategi Bundling dan Cross-Selling

Hasil analisis menunjukkan kombinasi produk dengan confidence tinggi berpotensi untuk strategi *bundling*. Contoh penerapan (Berry & Linoff, 2004):

- Paket "Mie Instan + Saus Sachet" dengan confidence 82% dapat ditawarkan dengan harga khusus. Estimasi: harga satuan total Rp 17.000 ditawarkan Rp 15.000 (diskon 12%). Dengan asumsi 30% dari 1.200 transaksi (360 pelanggan) membeli paket ini, potensi peningkatan pendapatan Rp 5.400.000 per bulan.
- Paket "Minuman Botol + Snack Ringan" dengan confidence 79% cocok untuk promosi akhir pekan. Penempatan di area kasir dapat meningkatkan *impulse buying* (Prasetyo & Utami, 2018).

2. Penataan Produk di Rak

- Produk dengan asosiasi kuat ditempatkan berdekatan untuk memudahkan konsumen menemukan produk pelengkap (Berry & Linoff, 2004).
- Produk impulsif ditempatkan di area strategis seperti *end-rack* atau dekat kasir untuk memicu pembelian spontan (Hidayat, 2020).

3. Manajemen Stok dan Pengadaan

- Produk pola rutin memiliki permintaan dapat diprediksi, cocok untuk sistem *auto-replenishment* dan kontrak jangka panjang dengan pemasok (Purba, 2021).
- Produk impulsif memerlukan sistem pemantauan stok dinamis karena fluktuasi permintaan tinggi (Rahayu, 2019).

4. Promosi Berbasis Waktu

- Pola impulsif meningkat akhir pekan, promosi difokuskan Jumat-Minggu (Laudon & Traver, 2020).
- Promosi *bundling* produk rutin dilakukan berkala setiap awal bulan (Kotler & Keller, 2016).

H. Evaluasi Metodologis

Pendekatan yang digunakan memiliki keunggulan: *FP-Growth* terbukti efisien menangani *dataset* 1.200 transaksi dan 87 item unik dengan waktu pemrosesan <5 detik (Sudhakar & Ramakrishna, 2021). Pembagian data 80:20 memberikan keyakinan aturan tidak *overfit* (Witten et al., 2016). Penggunaan tiga metrik (support, confidence, lift) memungkinkan penyaringan aturan komprehensif (Tan et al., 2019). Keterbatasan: threshold support dan confidence (5% dan 60%) mungkin tidak optimal untuk semua produk. Beberapa produk frekuensi rendah tetapi margin tinggi mungkin terlewatkan (Moro et al., 2014). Data anonim membatasi analisis segmentasi (Rakesh & Srikant, 2000). Periode tiga bulan tidak cukup menangkap variasi musiman (Rahayu, 2019).

4. DISKUSI

A. Analisis Kritis Temuan

1. Mengapa Pola Rutin dan Impulsif Muncul?

Pola rutin muncul karena konsumen memiliki kebutuhan dasar relatif tetap dan pola konsumsi stabil. Produk seperti mi instan, minyak goreng, dan gula merupakan kebutuhan sehari-hari yang harus dipenuhi teratur. Konsumen cenderung membeli produk ini dalam jumlah tertentu dengan kombinasi terbentuk dari pengalaman belanja sebelumnya (Kotler & Keller, 2016).

Pola impulsif muncul karena stimulus eksternal memicu keputusan pembelian mendadak. Faktor penempatan produk strategis, promosi harga, cuaca, atau suasana hati konsumen dapat memicu pembelian impulsif (Berry & Linoff, 2004). Produk seperti snack, minuman, dan permen memiliki karakteristik mendukung pembelian impulsif: harga relatif murah, daya tarik visual, dan keputusan pembelian cepat (Prasetyo & Utami, 2018).

2. Faktor-Faktor yang Mempengaruhi Pola Pembelian

Beberapa faktor mempengaruhi pola pembelian di PT XYZ (Rahayu, 2019):

- **Demografis Konsumen:** Mayoritas konsumen adalah karyawan industri di Batam. Mereka cenderung belanja terencana di awal bulan (setelah gaji) dan impulsif di akhir pekan (Purba, 2021).
- **Geografis dan Iklim:** Iklim tropis Batam yang panas meningkatkan permintaan minuman botol, terutama siang hari. Ini menjelaskan asosiasi kuat minuman botol dengan snack ringan (Hidayat, 2020).
- **Ekonomi:** Sebagai kota industri dengan mobilitas tinggi, produk praktis seperti mi instan menjadi pilihan utama (Rahayu, 2019).
- **Pemasaran:** Kebijakan promosi dan penempatan produk mempengaruhi pola pembelian. Produk di area kasir atau *end-rack* memiliki probabilitas lebih tinggi dibeli impulsif (Berry & Linoff, 2004).

3. Implikasi bagi Strategi Bisnis (Laudon & Traver, 2020)

- **Segmentasi Pelanggan:** Konsumen pola rutin diberikan program loyalitas, konsumen impulsif didekati dengan promosi kejutan (Kotler & Keller, 2016).
- **Optimalisasi Tata Letak:** Memahami karakteristik berbeda memungkinkan perancangan tata letak mengakomodasi kedua perilaku (Berry & Linoff, 2004).
- **Manajemen Promosi:** Promosi disesuaikan waktu dan segmen. Bundling produk rutin di awal bulan, promosi impulsif di akhir pekan (Purba, 2021).

B. Pertimbangan Kontekstual

Pengaruh Musim dan Hari Libur: Meskipun tidak mencakup periode panjang, beberapa pola teridentifikasi: impulsif meningkat akhir pekan, rutin mendominasi awal bulan, permintaan kebutuhan pokok meningkat menjelang hari libur besar (Rahayu, 2019).

Pengaruh Faktor Eksternal: Kenaikan harga bahan pokok dapat mengurangi pembelian atau beralih ke substitusi (Moro et al., 2014). Kondisi ekonomi mempengaruhi perilaku; dalam resesi, konsumen lebih selektif dan mengurangi pembelian impulsif (Laudon & Traver, 2020).

C. Rekomendasi Pengembangan Sistem

1. **Integrasi dengan ERP:** Hasil MBA diintegrasikan dengan ERP untuk mendukung pengadaan otomatis, manajemen promosi, dan perencanaan stok dengan peringatan dini (Purba, 2021).
2. **Dashboard Analitik:** Dashboard real-time memantau aturan asosiasi terkini, kinerja promosi, dan tren pembelian (Hahsler et al., 2007).
3. **Sistem Rekomendasi:** Sistem berbasis aturan asosiasi dikembangkan di POS untuk memberikan rekomendasi produk pelengkap saat transaksi (Sudhakar & Ramakrishna, 2021).

D. Keterbatasan dan Arah Penelitian Selanjutnya

Keterbatasan (Tan et al., 2019; Larose, 2015):

1. Cakupan data terbatas (satu perusahaan, satu lokasi, tiga bulan)
2. Tidak ada data demografis pelanggan
3. Faktor eksternal tidak terukur
4. Tidak ada validasi eksperimental

Arah Penelitian Selanjutnya (Sudhakar & Ramakrishna, 2021; Hidayat, 2020; Prasetyo & Utami, 2018):

1. Memperluas cakupan data minimal satu tahun
2. Menambahkan data demografis pelanggan
3. Membandingkan *FP-Growth* vs Apriori vs Eclat (Zaki, 2000)
4. Mengintegrasikan data harga, promosi, dan aktivitas pesaing (Moro et al., 2014)
5. Uji coba lapangan strategi *bundling* (Berry & Linoff, 2004)
6. Membangun sistem rekomendasi real-time terintegrasi POS (Sudhakar & Ramakrishna, 2021)

5. KESIMPULAN

Penelitian ini mengidentifikasi dua skenario pola pembelian konsumen di PT XYZ menggunakan *FP-Growth*: pola rutin (mi instan-sambal, minyak goreng-gula) dengan confidence 74-82%, dan pola impulsif (minuman-snack, permen-tisu) dengan confidence 65-79%. Pola rutin memungkinkan strategi pengadaan otomatis dan promosi berkala, sedangkan pola impulsif mendukung strategi display kasir dan promosi waktu terbatas. Pendekatan *hybrid* dalam tata letak toko, pengelolaan stok, dan promosi direkomendasikan. *Market Basket Analysis* terbukti sebagai

landasan pengambilan keputusan bisnis berbasis data dan berorientasi pelanggan (Berry & Linoff, 2004; Purba, 2021).

6. REFERENSI

- Agrawal, R. and Srikant, R. (1994) 'Fast algorithms for mining association rules', in Proceedings of the 20th International Conference on Very Large Data Bases (VLDB), pp. 487-499.
- Berry, M.J.A. and Linoff, G.S. (2004) Data Mining Techniques: For Marketing, Sales, and Customer Relationship Management. 2nd edn. Hoboken: Wiley.
- Chen, M.S., Han, J. and Yu, P.S. (1996) 'Data mining: an overview from a database perspective', IEEE Transactions on Knowledge and Data Engineering, 8(6), pp. 866-883. DOI: 10.1109/69.553155.
- Hahsler, M., Chelluboina, S., Hornik, K. and Buchta, C. (2007) 'The arules R-package ecosystem: Analyzing interesting patterns from large transaction data sets', Journal of Machine Learning Research, 12, pp. 2021-2025.
- Han, J., Pei, J. and Kamber, M. (2011) Data Mining: Concepts and Techniques. 3rd edn. Burlington: Morgan Kaufmann.
- Hidayat, N. (2020) 'Analisis pola pembelian konsumen menggunakan algoritma apriori pada toko ritel', Jurnal Teknik Informatika, 14(2), pp. 89-96.
- Kotler, P. and Keller, K.L. (2016) Marketing Management. 15th edn. Boston: Pearson Education.
- Larose, D.T. (2015) Discovering Knowledge in Data: An Introduction to Data Mining. 2nd edn. Hoboken: Wiley.
- Laudon, K.C. and Traver, C.G. (2020) E-commerce: Business, Technology, Society. 16th edn. Boston: Pearson.
- Liu, B., Hsu, W. and Ma, Y. (1998) 'Integrating classification and association rule mining', in Proceedings of the Fourth International Conference on Knowledge Discovery and Data Mining (KDD), pp. 80-86.
- Moro, S., Cortez, P. and Rita, P. (2014) 'A data-driven approach to predict the success of bank telemarketing', Decision Support Systems, 62, pp. 22-31. DOI: 10.1016/j.dss.2014.03.001.
- Prasetyo, E. and Utami, L. (2018) 'Implementasi market basket analysis pada toko minimarket berbasis algoritma *FP-Growth*', Jurnal Teknologi dan Sistem Komputer, 6(1), pp. 45-50.
- Purba, J.T. (2021) Big Data Analytics: Konsep dan Praktik di Industri Ritel Modern Indonesia. Jakarta: Gramedia Pustaka Utama.
- Rahayu, S. (2019) 'Data mining dalam perilaku konsumen: Studi penerapan di lingkup usaha mikro', Jurnal Ekonomi dan Bisnis, 22(1), pp. 15-27.
- Rakesh, A. and Srikant, R. (2000) 'Privacy-preserving data mining', ACM SIGMOD Record, 29(2), pp. 439-450. DOI: 10.1145/335191.335438.
- Sudhakar, R. and Ramakrishna, M. (2021) 'A market basket analysis using apriori algorithm and *FP-Growth*', International Journal of Engineering Research & Technology (IJERT), 10(03), pp. 504-508.
- Tan, C.N.L., Chong, S.C. and Lin, B. (2013) 'Intellectual capital and knowledge management linkages in Malaysian ICT companies', Journal of Intellectual Capital, 14(2), pp. 206-226.
- Tan, P.N., Steinbach, M. and Kumar, V. (2019) Introduction to Data Mining. 2nd edn. Boston: Pearson Education.
- Witten, I.H., Frank, E., Hall, M.A. and Pal, C.J. (2016) Data Mining: Practical Machine Learning Tools and Techniques. 4th edn. Burlington: Morgan Kaufmann.
- Zaki, M.J. (2000) 'Scalable algorithms for association mining', IEEE Transactions on Knowledge and Data Engineering, 12(3), pp. 372-390. DOI: 10.1109/69.846291.