Indonesian Journal of Digital Business

Journal homepage: https://ejournal.upi.edu/index.php/IJDB

Rancang Bangun Sistem Analisis Pola Pembelian Konsumen Menggunakan Metode Association Rules Pada Data Transaksi

*Novita Sari Siregar[1], Khairi Budayawan[2, *], Yeka Hendriyani[3], Yulia Fatmi[4]*

[1]Departemen Elektronika/Fakultas Teknik/Program Studi Informatika, Universitas Negeri Padang, Indonesia
Correspondence: E-mail: novitas98776@gmail.com

ABSTRAK

Data transaksi penjualan dapat dimanfaatkan untuk mengenali produk yang cenderung dibeli secara bersamaan. Penelitian ini bertujuan mengembangkan sistem web analisis pola pembelian menggunakan Association Rules dengan algoritma Apriori, menguji fungsi dan penerimaan pengguna, serta membandingkan hasilnya dengan implementasi Python dan RapidMiner. Penelitian menggunakan dataset publik UMKM Food and Beverage yang pada tahap awal terdiri atas 53.820 struk dan 11 atribut. Setelah transaksi satu produk dikecualikan, analisis dilakukan terhadap 8.153 transaksi dan 94 produk. Hasil Black Box Testing menunjukkan bahwa seluruh 13 skenario berjalan sesuai harapan. Uji penerimaan pengguna memperoleh skor 78% dari Admin dan 88% dari Manajer, dengan rata-rata 83% dari dua responden. Pada subset training 90%, aturan Donat Polos → Candy Latte ditemukan pada Python dan sistem web, tetapi nilai support, confidence, dan lift yang dihasilkan berbeda. Beberapa aturan pada keluaran RapidMiner juga tercatat pada label subset yang berbeda, sementara parameter pengujian belum terdokumentasi secara seragam. Dengan demikian, penelitian ini menghasilkan sistem yang berfungsi sesuai skenario yang diuji, tetapi perbandingan lintas implementasi masih memerlukan pengujian lanjutan dengan konfigurasi yang sama. Kontribusi penelitian terletak pada integrasi alur analisis dan evaluasi sistem web, bukan pada pengembangan algoritma baru.

ARTICLE INFO

Article History:
Submitted/Received 21 October 2026
First Revised 23 October 2026
Accepted 30 October 2026
First Available online 6 November 2026
Publication Date 6 November 2026

Keyword:
Apriori Association Rules, Analisis Pola Pembelian, Data Transaksi, Sistem Web

1. LATAR BELAKANG

Data transaksi penjualan menyimpan informasi tentang produk yang dibeli secara bersamaan. Informasi tersebut dapat membantu pengelola memahami kecenderungan pembelian dan menjadi bahan pertimbangan dalam merencanakan promosi atau bundling. Ketika jumlah transaksi dan variasi produk meningkat, analisis manual menjadi kurang efisien. Data mining dan market basket analysis dapat digunakan untuk mengekstraksi pola keterkaitan antarproduk dari data transaksi (Rahmi & Mikola, 2021; Fatah & Aila, 2025). Data transaksi juga tidak hanya berfungsi sebagai arsip penjualan, tetapi dapat dimanfaatkan sebagai informasi yang membantu pengambilan keputusan (Hari, 2021). Pengelolaan data transaksi yang terus bertambah menjadi hal penting dalam pengembangan strategi bisnis, termasuk strategi pemasaran dan penjualan (Rhomadhona et al., 2021). Sistem informasi berbasis web yang mengotomatiskan pengolahan data juga dilaporkan dapat mengurangi ketergantungan pada proses manual yang berpotensi tidak efisien (Budayawan et al., 2025) serta memudahkan pihak terkait mengakses informasi terbaru (Thamrin et al., 2021). Pemanfaatan perdagangan elektronik juga dipandang berperan dalam mendukung ekonomi digital (Handayani, 2022), sementara sistem informasi e-commerce berbasis web dapat menunjang kegiatan penjualan (Anna et al., 2022).

Association Rules menyatakan keterkaitan dalam bentuk aturan A → B. Support menunjukkan proporsi transaksi yang memuat kombinasi item, confidence menunjukkan proporsi transaksi yang memuat B di antara transaksi yang memuat A, dan lift membandingkan kemunculan bersama dengan kemunculan yang diharapkan apabila item independen. Apriori membentuk frequent itemset berdasarkan minimum support dan menghasilkan aturan berdasarkan minimum confidence (Sitanggang et al., 2023; Wijaya et al., 2023). Penerapan teknik data mining juga dapat membantu menemukan pola pembelian konsumen yang sebelumnya sulit diketahui melalui analisis manual (Anderson, 2023). Konsep data mining mencakup proses penggalian pengetahuan dari data untuk memperoleh informasi yang bermakna (Wororomi et al., 2024).

Penelitian terdahulu menggunakan metode dan fokus yang beragam untuk menemukan pola pembelian. Rahmi dan Mikola (2021) menerapkan Apriori pada transaksi Toko Bakoel Sembako; Fatah dan Aila (2025) menggunakan Apriori pada toko sembako dengan minimum support 18% dan minimum confidence 85,7%; Wijaya et al. (2023) menggunakan tahapan KDD dan Apriori dengan minimum support 3%, confidence 50%, dan lift ratio minimum 100%; sedangkan Sari dan Nuryana (2024) menggabungkan K-Means untuk customer segmentation dan Eclat untuk market basket analysis. Penelitian-penelitian tersebut menekankan penemuan pola transaksi, sementara penelitian ini menekankan integrasi proses unggah data, preprocessing, analisis, penyajian hasil, dan evaluasi aplikasi web. Selain itu, Nelisa dan Mutia (2022) menunjukkan bahwa algoritma Apriori dapat membantu menemukan pola pembelian yang dimanfaatkan untuk mendukung strategi penjualan dan pemasaran suatu usaha, sedangkan Syaifulloh et al. (2024) menyatakan bahwa analisis pola pembelian pelanggan dapat membantu perusahaan meningkatkan strategi pemasaran dan memahami perilaku konsumen secara lebih mendalam. Penerapan market basket analysis dengan Apriori juga telah dilakukan pada transaksi ritel (Rizaldi & Adnan, 2021), sedangkan Apriori digunakan untuk menganalisis pola pembelian konsumen pada penelitian Putri dan Sitohang (2023).

Ringkasan penelitian terdahulu dan posisi penelitian ini disajikan pada Tabel 1.

Tabel 1 Ringkasan Penelitian Terdahulu

Penelitian	Metode/fokus	Informasi yang tersedia	Posisi penelitian ini
Rahmi & Mikola (2021)	Apriori untuk menemukan pola pembelian pada Toko Bakoel Sembako.	Abstrak menjelaskan objek dan tujuan; jumlah transaksi dan fitur aplikasi tidak disebutkan pada abstrak.	Studi berfokus pada penerapan Apriori pada toko tertentu; penelitian ini menambahkan integrasi alur web dan evaluasi sistem.
Fatah & Aila (2025)	Apriori pada toko sembako; minimum support 18% dan confidence 85,7%.	Abstrak menyebut ambang parameter dan contoh kategori produk; jumlah transaksi serta fitur aplikasi tidak disebutkan pada abstrak.	Penelitian ini memakai data F&B publik dan membandingkan hasil beberapa implementasi.
Wijaya et al. (2023)	Apriori dengan tahapan KDD; minimum support 3%, confidence 50%, dan lift ratio minimum 100%.	Abstrak memberi contoh aturan Medialuna → Coffee dengan support 3,5%, confidence 57%, lift 120%; ukuran data dan fitur aplikasi tidak disebutkan pada abstrak.	Penelitian ini berfokus pada integrasi proses analisis dalam web dan uji fungsi/penerimaan.
Sari & Nuryana (2024)	K-Means untuk customer segmentation dan Eclat untuk market basket analysis.	Publikasi menjelaskan penggunaan dua metode; jumlah transaksi dan fitur aplikasi tidak dijelaskan pada metadata/abstrak yang ditinjau.	Penelitian ini berfokus pada Apriori dan membandingkan keluaran implementasi Apriori.

Tabel 1 memperlihatkan bahwa penelitian terdahulu menggunakan metode dan konteks data yang beragam. Informasi mengenai ukuran dataset, fitur aplikasi, dan keterbatasan tidak tersedia secara seragam pada seluruh publikasi yang ditinjau. Oleh karena itu, posisi penelitian ini difokuskan pada integrasi proses analisis transaksi dalam sistem web serta evaluasi fungsi dan penerimaan pengguna. Selain itu, penelitian membandingkan keluaran Apriori dari beberapa implementasi untuk mengidentifikasi kesesuaian dan perbedaan hasilnya.

Penelitian menggunakan dataset publik UMKM Food and Beverage yang dipublikasikan melalui Mendeley Data. Dataset tersebut berasal dari tiga outlet selama Januari–September 2025. Aciak Mart dilibatkan sebagai pihak yang memberi penilaian pada UAT, sedangkan data transaksi Aciak Mart tidak digunakan untuk membentuk aturan asosiasi. Oleh karena itu, pola dari dataset F&B publik tidak dapat langsung digeneralisasi sebagai pola pembelian konsumen Aciak Mart.

Tujuan penelitian adalah membangun sistem analisis pola pembelian konsumen berbasis web menggunakan Association Rules dengan algoritma Apriori, mengevaluasi

fungsi dan penerimaan pengguna, serta membandingkan hasil Apriori pada sistem web dengan Python dan RapidMiner. FP-Growth pada Python dan RapidMiner digunakan sebagai pembanding algoritmik tambahan

2. METODE PENELITIAN

2.1 Metode Pengembangan Sistem

Sistem dikembangkan menggunakan metode Prototype, meliputi Communication, Quick Plan, Modeling Quick Design, Construction of Prototype, serta Deployment, Delivery & Feedback (Yunita et al., 2021). Pengembangan mencakup identifikasi kebutuhan, perancangan UML, basis data dan antarmuka, pembangunan prototipe, pengujian, serta pengumpulan umpan balik. Aplikasi web menggunakan Laravel/PHP, layanan analisis menggunakan Python dan FastAPI, pengolahan data menggunakan Pandas dan Mlxtend, serta penyimpanan data menggunakan MySQL. Berbeda dengan penelitian ini yang menggunakan metode Prototype, sistem pada Thamrin et al. (2021) dan Budayawan et al. (2025) dikembangkan dengan metode Waterfall. Pemanfaatan UML dalam perancangan sistem informasi berbasis web juga dibahas oleh Aurellia et al. (2025).

Fitur sistem mencakup login, dashboard, pengelolaan dan pratinjau dataset, preprocessing, analisis Apriori, penyajian hasil dan insight, laporan, serta profil pengguna. Hak akses Admin dan Manajer dibedakan sesuai kebutuhan operasional sistem.

2.2 Data dan Preprocessing

Berkas CSV mentah yang diperiksa terdiri atas 53.820 baris dan 11 atribut. Seluruh 53.820 ReceiptNumber terisi dan unik; kolom Items juga tidak memiliki nilai kosong. Pemeriksaan menemukan 0 baris duplikat penuh dan 0 ReceiptNumber duplikat. Kolom TotalItem menunjukkan 45.667 struk dengan satu produk dan 8.153 struk dengan dua produk; tidak ditemukan struk dengan jumlah item selain satu atau dua. Daftar Items pada setiap baris sesuai dengan nilai TotalItem dan tidak ditemukan nama produk berulang di dalam satu struk. Karena aturan asosiasi membutuhkan transaksi dengan sekurang-kurangnya dua item, 45.667 struk satu-item tidak disertakan dalam matriks analisis. Sebanyak 8.153 transaksi dua-item digunakan untuk membentuk matriks biner dengan 94 produk. Dengan demikian, 45.667 merupakan jumlah struk satu-item yang dikecualikan dari analisis asosiasi, bukan jumlah baris duplikat atau baris kosong yang dihapus. Ringkasan hasil audit data transaksi disajikan pada Tabel 2.

Tabel 2 Hasil Audit Data Transaksi CSV

Indikator	Nilai hasil audit CSV	Keterangan
Jumlah baris/struk pada CSV mentah	53.820	Setiap baris memiliki satu ReceiptNumber.
Jumlah atribut pada CSV mentah	11	Atribut awal pada berkas CSV.
Jumlah kolom setelah ReceiptNumber dikeluarkan	10	Jumlah baris tetap 53.820; ReceiptNumber tidak digunakan sebagai atribut produk.
ReceiptNumber kosong	0	Tidak ditemukan nilai kosong atau teks kosong.
Items kosong	0	Tidak ditemukan nilai kosong atau

		teks kosong.
Baris duplikat penuh	0	Pemeriksaan seluruh kolom.
ReceiptNumber duplikat	0	Seluruh nomor struk unik.
Jumlah struk unik	53.820	Sama dengan jumlah baris CSV mentah.
Struk dengan 1 produk	45.667	Dikecualikan dari analisis asosiasi karena hanya memuat satu item.
Struk dengan 2 produk	8.153	Dipertahankan sebagai transaksi untuk analisis asosiasi.
Struk dengan jumlah item selain 1 atau 2	0	Nilai TotalItem sesuai dengan jumlah nama produk dalam kolom Items.
Produk unik	94	Produk yang menjadi kolom pada matriks transaksi.
Data akhir untuk analisis	8.153 transaksi × 94 produk	Matriks biner; 1 berarti produk ada dan 0 berarti tidak ada.

Dari 53.820 struk pada berkas awal, sebanyak 45.667 struk hanya memuat satu produk dan 8.153 struk memuat dua produk. Karena analisis asosiasi membutuhkan transaksi yang memuat sekurang-kurangnya dua item, struk satu produk tidak disertakan dalam pembentukan matriks analisis. Pemeriksaan juga menunjukkan tidak adanya nilai kosong pada ReceiptNumber atau Items, tidak adanya baris duplikat penuh, serta tidak adanya ReceiptNumber duplikat. Dengan demikian, pengurangan jumlah transaksi yang dianalisis berasal dari pemilihan struk sesuai kriteria analisis, bukan dari penghapusan data duplikat atau data kosong.

2.3 Algoritma dan Konfigurasi Eksperimen

Data analisis direpresentasikan sebagai matriks biner berukuran 8.153 transaksi × 94 produk; nilai 1 menunjukkan produk terdapat dalam transaksi dan nilai 0 menunjukkan produk tidak terdapat dalam transaksi. Apriori diterapkan pada sistem web, Python, dan RapidMiner. FP-Growth pada Python dan RapidMiner digunakan sebagai metode pembanding tambahan. Pengujian dilaporkan menggunakan pembagian data training 90%, testing 5%, dan validation 5%. Namun, jumlah transaksi aktual pada setiap subset serta penggunaan random seed belum didokumentasikan secara lengkap, sehingga konsistensi pembagian data antarimplementasi perlu dipastikan. Penggunaan FP-Growth sebagai pembanding sejalan dengan penelitian Syaifulloh et al. (2024) yang membandingkan algoritma Squeezer, Apriori, dan FP-Growth pada analisis pola pembelian pelanggan toko bangunan. Ringkasan dataset dan konfigurasi eksperimen disajikan pada Tabel 3.

Tabel 3 Ringkasan Dataset dan Konfigurasi Eksperimen

Komponen	**Informasi yang terdokumentasi**	**Batasan informasi**
Dataset	CSV mentah 53.820 baris/struk dan 11 atribut; 8.153 struk dua-item dianalisis dengan 94 produk.	Tidak ditemukan ReceiptNumber kosong, Items kosong, baris duplikat penuh, atau ReceiptNumber duplikat.
Pembagian data	Pengujian menggunakan proporsi training 90%, testing 5%, dan	Jumlah transaksi aktual setiap subset dan konsistensi

	validation 5%.	pembagian antarimplementasi perlu dipastikan.
Algoritma utama	Apriori diterapkan pada sistem web, Python, dan RapidMiner.	Pada beberapa keluaran, label subset tidak konsisten dengan label yang digunakan pada perbandingan aturan.
Metode pembanding	FP-Growth diterapkan pada Python dan RapidMiner sebagai pembanding tambahan.	Hasil numerik FP-Growth belum disajikan secara rinci dalam tabel perbandingan.
Minimum confidence	RapidMiner: 0,01 pada beberapa skenario; Python validation: 0,01.	Belum tersedia bukti bahwa nilai yang sama digunakan pada seluruh skenario dan implementasi.
Minimum support	RapidMiner: 0 dengan 1 instance pada beberapa skenario; Python validation: 0,002457 (0,2457%).	Nilai minimum support sistem web dan konfigurasi pada setiap subset belum didokumentasikan secara konsisten.
Perangkat lunak dan pustaka	Laravel/PHP, Python, FastAPI, Pandas, Mlxtend, MySQL, dan RapidMiner.	Versi perangkat lunak/pustaka dan penggunaan random seed belum dicantumkan.
Evaluasi	Black Box Testing terhadap 13 skenario; UAT oleh dua pengguna; perbandingan aturan, support, confidence, dan lift jika tersedia.	Perbandingan seluruh frequent itemset dan aturan dengan konfigurasi identik belum ditunjukkan.

Konfigurasi yang tersedia belum menunjukkan bahwa seluruh implementasi menggunakan subset data, parameter, dan definisi transaksi yang sama. Pada beberapa keluaran RapidMiner, minimum support dicatat sebesar 0 dengan 1 instance dan minimum confidence 0,01, sedangkan pengujian validation Python mencatat minimum support 0,002457 (sekitar 0,2457%) dan minimum confidence 0,01. Nilai minimum support pada sistem web serta versi perangkat lunak dan pustaka belum dirinci secara konsisten. Oleh sebab itu, hasil yang disajikan diperlakukan sebagai perbandingan keluaran yang tersedia, bukan sebagai validasi menyeluruh dengan konfigurasi identic.

2.4 Pengujian Sistem

Black Box Testing digunakan untuk memeriksa fungsi sistem berdasarkan skenario pengujian. UAT dilakukan dengan kuesioner kepada dua pengguna Aciak Mart, yaitu Admin dan Manajer. Jumlah responden yang terbatas berarti hasil UAT merupakan evaluasi awal dari kedua pengguna tersebut dan tidak mewakili seluruh calon pengguna. Black Box Testing berfokus pada pengujian fungsi sistem berdasarkan kebutuhan pengguna tanpa melihat struktur internal program (Jibril et al., 2024). Kombinasi Black Box Testing dan User Acceptance Test juga digunakan pada sistem informasi pendataan warga dengan 40 responden dan persentase penerimaan 90,5% (Thamrin et al., 2021); jumlah responden UAT pada penelitian ini jauh lebih sedikit sehingga hasilnya perlu ditafsirkan dengan lebih hati-hati.

3. Hasil dan Pembahasan

3.1. Hasil Perancangan Sistem

Sistem menyediakan alur pengolahan mulai dari pengunggahan dataset, preprocessing, pengaturan parameter, analisis Apriori, hingga penyajian frequent itemset dan aturan asosiasi. Pengujian Black Box menunjukkan bahwa seluruh 13 skenario yang diuji berjalan sesuai hasil yang diharapkan. Ringkasan hasil UAT ditampilkan pada Tabel 4.

Table 4 Hasil User Acceptance Test (UAT)

Pengguna	Skor diperoleh	Skor maksimal	Persentase
Admin	39	50	78%
Manajer	44	50	88%
Keseluruhan	83	100	83%

UAT menghasilkan nilai 78% dari Admin dan 88% dari Manajer, dengan rata-rata keseluruhan 83%. Nilai tersebut menunjukkan penilaian dari dua responden yang berpartisipasi. Hasil ini tidak boleh ditafsirkan sebagai ukuran penerimaan seluruh pengguna karena jumlah responden hanya dua orang.

3.2. Hasil Perbandingan Association Rules

Pada subset training 90%, Python menghasilkan aturan Donat Polos → Candy Latte dengan support 0,12%, confidence 6,21%, dan lift 2,8685. Sistem web menghasilkan aturan yang sama dengan support 0,11%, confidence 5,48%, dan lift 2,5288. Sementara itu, aturan Donat Polos → Candy Latte tidak tercantum pada keluaran RapidMiner untuk training 90%; aturan tersebut muncul pada keluaran RapidMiner untuk testing 5%, dengan confidence 5% dan delapan kemunculan. Perbedaan label subset ini membuat hasil RapidMiner belum dapat dibandingkan langsung dengan hasil Python dan sistem web pada training 90%. Perbandingan aturan asosiasi pada subset training 90% disajikan pada Tabel 5.

Tabel 5 Perbandingan Aturan Asosiasi pada Training 90%

Data pengujian	Aturan asosiasi	Implementasi	Support	Confidence	Lift/catatan
Training 90%	Donat Polos → Candy Latte	Python	0,12%	6,21%	2,8685
Training 90%	Donat Polos → Candy Latte	Sistem web	0,11%	5,48%	2,5288
Testing 5%	Donat Polos → Candy Latte	RapidMiner	Tidak dicantumkan	5%	8 kemunculan; tidak boleh dibandingkan langsung dengan training 90%

Hasil Python dan sistem web pada training 90% memuat aturan dengan antecedent dan consequent yang sama, tetapi nilai support, confidence, dan lift berbeda. Pada keluaran RapidMiner, aturan tersebut tercatat pada subset testing 5%, bukan training 90%. Karena

itu, kesamaan aturan saja belum cukup untuk menyatakan ketiga implementasi menghasilkan keluaran yang setara; subset data dan parameter yang digunakan perlu diperiksa terlebih dahulu. Penggunaan Association Rules untuk mengidentifikasi pola pembelian dan keterkaitan antarproduk juga dilaporkan pada penelitian Rizaldi dan Adnan (2021) serta Wijaya et al. (2023), sehingga temuan ini dapat dipahami dalam konteks penerapan analisis asosiasi pada data transaksi.

Pada subset testing 5%, sistem web menghasilkan aturan Burnt Sugar → Basic Latte (Ice Houseblend) dengan support 0,25%, confidence 100%, dan lift 51,0. Aturan yang sama tercatat pada keluaran RapidMiner untuk validation 5%, dengan confidence 100% dan satu kemunculan. Karena label subset berbeda, kedua hasil ini belum dapat diperlakukan sebagai perbandingan langsung sebelum data masukan dan pembagian subset diverifikasi.

Pada subset validation 5%, sistem web menghasilkan aturan Friendly Coffee (Gede) → Americano (Hot Arabica) dengan support 0,25%, confidence 33,33%, dan lift 33,9. Python juga melaporkan aturan tersebut dengan support 0,24%; namun, confidence ditampilkan sebagai 0,33 pada tabel dan 33,33% pada uraian. Nilai ini perlu diperiksa pada keluaran Python untuk memastikan konsistensi format. Sementara itu, aturan yang sama tercatat pada keluaran RapidMiner untuk training 90%, dengan confidence 33% dan satu kemunculan. Perbedaan label subset dan format confidence membuat hasil ini belum dapat dianggap sebagai validasi tiga implementasi yang konklusif. Ringkasan perbandingan aturan asosiasi antarimplementasi disajikan pada Tabel 6.

Tabel 6 Ringkasan Perbandingan Aturan Asosiasi Antariplementasi

Pembagian data	Aturan contoh	Ringkasan hasil yang dilaporkan	Status pembandingan
Training 90%	Donat Polos → Candy Latte	Python: support 0,12%, confidence 6,21%, lift 2,8685; sistem web: support 0,11%, confidence 5,48%, lift 2,5288. Aturan ini tidak tercantum pada keluaran RapidMiner training 90%, tetapi muncul pada keluaran testing 5%.	Python dan sistem web menggunakan label training 90%, tetapi nilai metrik berbeda. Hasil RapidMiner belum dapat dipasangkan langsung karena tercatat pada subset testing 5%.
Testing 5%	Burnt Sugar → Basic Latte (Ice Houseblend)	Sistem web: support 0,25%, confidence 100%, lift 51,0. Keluaran RapidMiner validation 5% mencatat confidence 100% dan satu kemunculan.	Label subset berbeda antara sistem web dan RapidMiner; data masukan dan pembagian subset perlu diverifikasi.
Validation 5%	Friendly Coffee (Gede) → Americano (Hot Arabica)	Sistem web: support 0,25%, confidence 33,33%, lift 33,9. Python: support 0,24%, confidence tercatat 0,33 pada tabel dan 33,33% pada uraian. Keluaran RapidMiner training 90% mencatat confidence 33%.	Format confidence Python dan label subset belum konsisten; hasil ini belum menjadi validasi tiga implementasi yang konklusif.

3.3 Pembahasan

Kontribusi utama penelitian ini adalah pengembangan sistem web yang mengintegrasikan pengunggahan dataset, preprocessing, analisis Apriori, dan penyajian hasil asosiasi. Seluruh 13 skenario Black Box Testing berjalan sesuai hasil yang diharapkan.

UAT menghasilkan nilai 78% dari Admin dan 88% dari Manajer, dengan rata-rata 83%. Hasil tersebut menggambarkan penilaian dua pengguna yang terlibat dan belum dapat mewakili penerimaan seluruh calon pengguna.

Pada training 90%, aturan Donat Polos → Candy Latte memiliki lift di atas satu pada Python dan sistem web, yang menunjukkan asosiasi positif dalam masing-masing keluaran. Namun, nilai metrik yang berbeda dan perbedaan label subset pada keluaran RapidMiner membuat perbandingan lintas implementasi belum konklusif. Aturan dengan confidence 100% pada pengujian sistem web hanya tercatat satu kali; karena itu, aturan tersebut perlu ditafsirkan secara hati-hati dan tidak dapat dianggap stabil tanpa pengujian tambahan. Association Rules menunjukkan keterkaitan statistik, bukan hubungan sebab-akibat, dan tidak dengan sendirinya membuktikan bahwa strategi bundling akan meningkatkan penjualan. Interpretasi aturan berdasarkan support, confidence, dan lift sejalan dengan penggunaan metrik tersebut dalam analisis pola transaksi pada penelitian Rhomadhona et al. (2021) dan Syaifulloh et al. (2024).

Penelitian ini tidak mengusulkan algoritma baru. Kontribusinya terletak pada integrasi pengelolaan dataset, preprocessing, analisis Apriori, penyajian aturan, insight, dan laporan dalam aplikasi web, disertai pengujian fungsi dan penerimaan pengguna. FP-Growth diterapkan pada Python dan RapidMiner sebagai pembanding tambahan, tetapi hasil numeriknya belum disajikan secara rinci dalam perbandingan. Oleh karena itu, penelitian ini belum menyimpulkan bahwa Apriori lebih baik atau lebih buruk daripada FP-Growth. Perbandingan algoritma yang lebih kuat perlu menggunakan transaksi dan ambang support yang sama, kemudian membandingkan frequent itemset serta metrik aturan yang dihasilkan. Penelitian terdahulu menunjukkan pemanfaatan Apriori, Eclat, dan K-Means untuk analisis transaksi, tetapi informasi ukuran data dan fitur aplikasi tidak tersedia secara seragam; perbandingan dengan penelitian terdahulu karena itu dibatasi pada informasi yang dapat diverifikasi. Penelitian Nelisa dan Mutia (2022) serta Anderson (2023) juga memperlihatkan pemanfaatan Apriori untuk menemukan pola pembelian yang mendukung strategi penjualan, sehingga hasil penelitian ini dapat dibaca sebagai bagian dari rangkaian penelitian serupa dengan integrasi sistem web sebagai fokus utamanya.

Penelitian ini memiliki beberapa keterbatasan. Dataset yang digunakan merupakan data F&B publik dan bukan transaksi aktual Aciak Mart, sehingga pola yang ditemukan tidak dapat langsung digeneralisasi ke usaha tersebut. UAT hanya melibatkan dua responden. Versi perangkat lunak dan pustaka, penggunaan random seed, serta jumlah transaksi pada setiap subset belum didokumentasikan secara lengkap. Selain itu, label subset dan parameter pada sebagian keluaran belum konsisten, dan hasil FP-Growth belum disajikan sebagai perbandingan numerik yang rinci. Penelitian lanjutan perlu menyamakan konfigurasi pengujian dan membandingkan seluruh frequent itemset serta aturan asosiasi pada data dan parameter yang setara.

4. KESIMPULAN

Penelitian ini menghasilkan sistem web analisis pola pembelian konsumen menggunakan Association Rules dengan algoritma Apriori. Sistem mendukung pengunggahan dan pengelolaan dataset, preprocessing, pengaturan parameter, serta penyajian frequent itemset dan aturan asosiasi. Seluruh 13 skenario Black Box Testing berjalan sesuai hasil yang

diharapkan. UAT menghasilkan nilai 78% dari Admin dan 88% dari Manajer, dengan rata-rata 83%; hasil tersebut hanya mewakili dua responden.

Pemeriksaan berkas CSV menunjukkan 53.820 baris/struk dan 11 atribut, tanpa nilai kosong pada ReceiptNumber maupun Items, tanpa baris duplikat penuh, dan tanpa ReceiptNumber duplikat. Setelah ReceiptNumber tidak digunakan sebagai atribut analisis, jumlah baris tetap 53.820 dengan 10 kolom. Sebanyak 45.667 struk satu produk dikecualikan dari analisis asosiasi, sedangkan 8.153 struk dua produk digunakan untuk membentuk matriks dengan 94 produk. Pada training 90%, aturan Donat Polos → Candy Latte ditemukan pada Python dan sistem web, tetapi nilai metriknya berbeda; keluaran RapidMiner mencatat aturan tersebut pada testing 5%. Temuan ini menunjukkan bahwa kesesuaian hasil perlu diperiksa berdasarkan label subset dan konfigurasi pengujian, bukan hanya berdasarkan nama aturan.

Sistem yang dikembangkan telah berjalan sesuai skenario Black Box Testing yang diuji dan memperoleh rata-rata penilaian UAT sebesar 83% dari dua responden. Namun, perbandingan hasil algoritma belum dapat dinyatakan konklusif karena terdapat perbedaan nilai metrik, label subset, dan dokumentasi parameter pada sejumlah keluaran. Sebelum kesetaraan hasil dapat disimpulkan, perlu dipastikan bahwa setiap implementasi menggunakan data masukan, pembagian subset, minimum support, minimum confidence, serta definisi transaksi yang sama. Versi perangkat lunak dan random seed jika digunakan juga perlu dicatat, kemudian seluruh frequent itemset dan aturan asosiasi dibandingkan. Karena analisis menggunakan dataset F&B publik, hasilnya tidak dapat langsung dianggap mewakili pola pembelian Aciak Mart.

5. UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada dosen pembimbing, dosen penguji, dan pihak yang memberikan arahan serta dukungan selama penelitian. Penulis juga berterima kasih kepada Admin dan Manajer Aciak Mart yang berpartisipasi dalam pengujian penerimaan sistem.

6. CATATAN PENULIS

Penulis menyatakan tidak memiliki konflik kepentingan yang berkaitan dengan penelitian dan penyusunan artikel ini.

7. REFERENSI

Anderson, J. (2023). Sistem pendeteksi pola pembelian konsumen menggunakan algoritma Apriori. Computatio: Journal of Computer Science and Information Systems, 7(1), 10–17.

Anna, R. S., & Putri, A. A. (2022). Pemanfaatan sistem informasi e-commerce berbasis web untuk mendukung kegiatan penjualan kosmetik. JUSTIAN: Jurnal Sistem Informasi Akuntansi, 3(1), 22–31

Budayawan, K., Ganefri, G., Anwar, M., Samala, A. D., Howard, N.-J., & Sandra, R. P. (2025). Predicting student graduation outcomes: An evaluation of project-based learning and implementation of Naïve Bayes. TEM Journal, 14(2), 1586–1601. https://doi.org/10.18421/TEM142-56

Aurellia, A., Nooriansyah, S., & Amrozi, Y. (2025). Pemanfaatan UML dalam perancangan sistem informasi produk kreatif daur ulang sampah berbasis web. JITET (Jurnal Informatika dan Teknik Elektro Terapan), 13(3S1). https://doi.org/10.23960/jitet.v13i3S1.8073

Fatah, Z., & Aila, S. (2025). Penerapan metode asosiasi menggunakan algoritma Apriori pada analisis pola pembelian konsumen (Studi kasus: Toko Sembako). JAMASTIKA, 4(2). https://doi.org/10.35473/jamastika.v4i2.4532

Hari, O. N. (2021). Penerapan data mining pada transaksi penjualan produk Herbalife Nutrition menggunakan metode Apriori. JUSTIAN, 2(1), 42–50. https://ejournal.bsi.ac.id/ejurnal/index.php/justian

Handayani, N. L. P. (2022). E-commerce sebagai penunjang ekonomi digital di Jawa Tengah. Jurnal Ilmiah Manajemen, Bisnis dan Kewirausahaan, 2(1), 9–14

Jibril, M., Zulrahmadi, & Amin, M. (2024). Pengujian sistem informasi e-modul pada SMPN 1 Tempuling menggunakan black box testing. Jurnal Perangkat Lunak, 6(2), 327–332.

Nelisa, & Mutia. (2022). Analisis data mining menggunakan transaksi penjualan untuk mengetahui pola pembelian konsumen pada Toko Endang Pasaman Barat memakai metode Apriori berbasis web. Journal of Information Technology and Accounting, 5(2), 57–64.

Rahmi, A. N., & Mikola, Y. A. (2021). Implementasi algoritma Apriori untuk menentukan pola pembelian pada customer (Studi kasus: Toko Bakoel Sembako). Information System Journal (INFOS), 4(1), 14–19. https://doi.org/10.24076/infosjournal.2021v4i1.561

Rizaldi, D., & Adnan, A. (2021). Market basket analysis menggunakan algoritma Apriori: Kasus transaksi 212 Mart Soebrantas Pekanbaru. Jurnal Statistika dan Aplikasinya, 5(1), 31–40. https://doi.org/10.21009/JSA.05103

Rhomadhona, H., Aprianti, W., & Permadi, J. (2021). Penerapan data mining terhadap data penjualan produk kopi menggunakan algoritma Apriori. Jurnal Sustainable: Jurnal Hasil Penelitian dan Industri Terapan, 10(2), 65–73. https://doi.org/10.31629/sustainable.v10i2.3792.

Sari, D. K., & Nuryana, I. K. D. (2024). Menganalisa pola pembelian pelanggan menggunakan metode data mining: Customer segmentation dan market basket analysis dengan algoritme K-Means dan Eclat. Journal of Emerging Information Systems and Business Intelligence (JEISBI), 5(2), 73–82. https://doi.org/10.26740/jeisbi.v5i2.60048.

Putri, S. D., & Sitohang, S. (2023). Analisis pola pembelian konsumen menggunakan algoritma Apriori. Jurnal Comasie, 9(7), 889.

Sitanggang, D., Turnip, M., Laia, Y., & Tamba, S. P. (2023). Algoritma Apriori. UNPRI Press, Universitas Prima Indonesia.

Syaifulloh, F., Puspaningrum, E. Y., & Al Haromainy, M. M. (2024). Analisis pola pembelian pelanggan menggunakan algoritma Squeezer, Apriori dan FP-Growth pada toko bangunan. Modem: Jurnal Informatika dan Sains Teknologi, 2(3), 134–147. https://doi.org/10.62951/modem.v2i3.153

Thamrin, Faiza, D., Hadi, A., Budayawan, K., Farell, G., & Novid, I. (2021). Designing the information system for data collection of Covid-19 symptoms for Indonesian citizens. Jurnal Teknologi Informasi dan Pendidikan, 14(1), 26–32. https://doi.org/10.24036/tip.v14i1

Wijaya, A., Faqih, A., Solihudin, D., Rohmat, C. L., & Permana, S. E. (2023). Penerapan Association Rules menggunakan algoritma Apriori untuk identifikasi pola pembelian. JATI (Jurnal Mahasiswa Teknik Informatika), 7(6), 3871–3878. https://doi.org/10.36040/jati.v7i6.8270

Wororomi, J. K., Reba, F., Mandowen, S. A., Sroyer, A. M., Manurung, H. E., Koibur, M. E., Pujiarini, E. H., Edy, M. R., Yuliana, H., Yusuf, M., & Dinata, R. M. (2024). Data mining (Memahami pola di balik angka). Penerbit CV Eureka Media Aksara.

Yunita, Y., Adriansyah, M., & Amalia, H. (2021). Sistem informasi bank sampah dengan model Prototype. INTI Nusa Mandiri, 16(1), 15. https://doi.org/10.33480/inti.v16i1.2269