

Comparative Performance of Apriori, FP-Growth, and ECLAT for Menu Bundling

Astriaana Putri Kumala Dewi¹, Noor Latifah², Supriyono³

Sistem Informasi, Universitas Muria Kudus

202253090@std.umk.ac.id¹, noor.latifah@umk.ac.id², supriyono.si@umk.ac.id³

Article Info

Article history:

Received 2026-07-24

Revised 2026-08-01

Accepted 2026-08-13

Keyword:

Apriori,
Association Rule Mining,
ECLAT,
FP-Growth,
Market Basket Analysis,
Menu Bundling.

ABSTRACT

Transaction data at Selaras Coffee and Space had not been systematically utilized to evaluate menu combinations or determine which association rule mining algorithm best suited the data characteristics. This study compares Apriori, FP-Growth, and ECLAT for generating menu-bundling recommendations. Sales records from 1–31 December 2025 were preprocessed by removing 950 operational transaction-item pairs, resulting in 6,213 transactions and 76 unique menus. The algorithms were evaluated on the same binary matrix using a minimum support of 0.01, a minimum confidence of 0.20, and a lift ratio greater than 1. The evaluation included parameter sensitivity, 30 repeated measurements of execution time and peak Python memory allocation, scalability using 25–100% of the transactions, and rule quality based on support, confidence, lift, leverage, conviction, and cosine similarity. All algorithms produced identical outputs of 68 frequent itemsets and five eligible rules. On the full dataset, ECLAT recorded the lowest mean execution time at 0.037701 s, followed by Apriori at 0.040419 s and FP-Growth at 0.069637 s. FP-Growth used the lowest mean peak memory at 1.026966 MB, while ECLAT showed the lowest runtime growth as the dataset size increased. The strongest rule was Mie Laksa → Air Mineral 330 ML, with a lift of 2.755987. These findings show that no algorithm dominated every criterion: ECLAT offered the best full-data runtime and scalability, FP-Growth was the most memory-efficient, and the extracted rules provided measurable candidates for menu-bundling strategies.



This is an open access article under the [CC-BY-SA](https://creativecommons.org/licenses/by-sa/4.0/) license.

I. PENDAHULUAN

Industri makanan dan minuman menghasilkan data transaksi yang dapat dianalisis untuk mengidentifikasi kombinasi produk yang sering muncul serta mendukung penyusunan strategi penjualan berbasis data [1]-[3]. Pada Selaras Coffee and Space, data tersebut memuat informasi mengenai menu-menu yang dibeli secara bersamaan dalam satu transaksi. Namun, data transaksi tersebut belum dimanfaatkan secara sistematis untuk mengevaluasi kombinasi menu sebagai rekomendasi bundling. Akibatnya, pemilihan menu untuk bundling belum sepenuhnya mencerminkan pola pembelian konsumen yang sebenarnya. Market basket analysis dapat digunakan untuk mengatasi permasalahan tersebut karena mampu mengidentifikasi hubungan pembelian antarproduk dan menyajikannya dalam bentuk aturan asosiasi yang terukur.

Salah satu pendekatan dalam *data mining* yang dapat digunakan untuk mengidentifikasi pola pembelian pelanggan adalah *association rule mining*. Metode ini bertujuan menemukan keterkaitan antaritem yang muncul secara bersamaan dalam suatu transaksi dan umum diterapkan pada *market basket analysis*. Pada penelitian ini, item yang dianalisis berupa menu-menu yang tercatat dalam data transaksi penjualan. Proses tersebut menghasilkan aturan asosiasi yang menggambarkan kecenderungan suatu menu dibeli bersamaan dengan menu lainnya. Kualitas setiap aturan diukur menggunakan nilai *support*, *confidence*, dan *lift ratio*. *Support* menunjukkan frekuensi kemunculan kombinasi menu dalam seluruh transaksi, *confidence* menggambarkan kemungkinan suatu menu dibeli ketika menu lain telah dipilih, sedangkan *lift ratio* digunakan untuk menilai kekuatan hubungan kedua menu dibandingkan dengan kemunculannya secara independen [3]-[5].

Apriori, FP-Growth, dan ECLAT dipilih dalam penelitian ini karena ketiganya merepresentasikan strategi pencarian frequent itemset yang berbeda. Apriori menggunakan pembentukan kandidat itemset secara bertahap dan mengeliminasi kandidat yang tidak memenuhi minimum support [4]. FP-Growth memanfaatkan struktur FP-Tree untuk menemukan frequent itemset tanpa melakukan pembentukan kandidat secara eksplisit [5]. Sementara itu, ECLAT menggunakan representasi data vertikal dengan menyimpan kumpulan ID transaksi atau TID-set untuk setiap item, kemudian menghitung kombinasi item melalui operasi irisan antarkumpulan tersebut [6], [7]. Pemilihan ketiga algoritma tidak didasarkan pada statusnya sebagai algoritma terbaru, tetapi pada perbedaan struktur data dan mekanisme pencarian yang digunakan. Perbedaan tersebut memungkinkan evaluasi yang terkontrol untuk mengetahui pengaruh mekanisme masing-masing algoritma terhadap hasil aturan asosiasi dan efisiensi komputasi pada dataset transaksi yang sama.

Kajian mengenai penerapan *association rule mining* pada data transaksi telah berkembang dalam beberapa arah. Pada konteks usaha kafe, Aditya et al. memanfaatkan algoritma Apriori untuk membentuk rekomendasi paket menu berbasis website [1]. Pendekatan serupa digunakan oleh Kurniana et al. dalam mengidentifikasi pola transaksi penjualan pada Cafe Sakuyan Side [2], sedangkan Muharmi dan Pulungan menerapkan Apriori untuk menghasilkan rekomendasi menu berdasarkan kecenderungan pembelian pelanggan [3]. Dalam konteks transaksi *food and beverage*, Marselina et al. menerapkan Apriori untuk mengidentifikasi kombinasi produk yang sering dibeli bersamaan sebagai dasar penyusunan strategi bisnis [8]. Sementara itu, Mandala et al. menerapkan FP-Growth untuk menentukan paket promosi berdasarkan aturan asosiasi dan nilai *lift* [9]. Penelitian lain lebih berfokus pada perbandingan kinerja algoritma. Karimah dan Udayanti membandingkan Apriori dengan FP-Growth pada transaksi penjualan buku daring [4], sementara Dwiputra et al. menilai performa aturan asosiasi yang dihasilkan kedua algoritma tersebut [5]. Perbandingan yang lebih luas dilakukan oleh Pujiharto et al. dan Wahyuningsih et al. dengan melibatkan Apriori, FP-Growth, serta ECLAT. Hasil penelitian mereka menunjukkan bahwa perbedaan mekanisme pemrosesan pada setiap algoritma dapat memengaruhi waktu komputasi, jumlah pola yang ditemukan, dan aturan asosiasi yang dihasilkan [6], [7].

Penerapan Market Basket Analysis juga telah dilakukan pada berbagai sektor usaha, termasuk usaha mikro, kecil, dan menengah, untuk mendukung penyusunan strategi pemasaran dan perancangan produk bundling [10], [11]. Dari sisi evaluasi algoritma, Husain et al. menunjukkan bahwa FP-Growth dan ECLAT dapat memiliki waktu komputasi yang lebih efisien dibandingkan Apriori karena tidak melakukan pembentukan kandidat secara berulang [12]. Temuan serupa diperoleh pada penelitian menggunakan data transaksi ritel dan pesanan makanan, yang menunjukkan bahwa penggunaan struktur FP-Tree dan representasi data vertikal dapat

memengaruhi efisiensi proses pencarian frequent itemset [13], [14]. Selain mekanisme algoritma, jumlah dan kualitas aturan asosiasi yang dihasilkan juga dipengaruhi oleh penentuan minimum support dan minimum confidence sehingga nilai ambang perlu disesuaikan dengan ukuran serta distribusi data transaksi yang dianalisis [15], [16].

Meskipun association rule mining telah banyak diterapkan pada data transaksi, penelitian pada usaha kafe umumnya menggunakan satu algoritma dan berfokus pada pembentukan rekomendasi produk [1]-[5], [8], [9]. Penelitian yang membandingkan Apriori, FP-Growth, dan ECLAT juga telah dilakukan, tetapi evaluasinya masih dominan berdasarkan jumlah frequent itemset, jumlah aturan asosiasi, dan waktu eksekusi pada satu kombinasi parameter [6], [7], [12]-[14]. Evaluasi yang menggabungkan sensitivitas minimum support dan minimum confidence, penggunaan memori, skalabilitas terhadap perubahan ukuran data, serta beberapa ukuran kualitas aturan dalam kondisi pengujian yang sama masih terbatas [15], [16]. Kondisi tersebut menyebabkan kesesuaian masing-masing algoritma terhadap karakteristik data transaksi usaha kafe belum dapat dinilai secara menyeluruh.

Kontribusi ilmiah penelitian ini terletak pada penyusunan kerangka evaluasi terkontrol terhadap Apriori, FP-Growth, dan ECLAT menggunakan dataset, tahapan preprocessing, lingkungan komputasi, dan parameter pengujian yang sama. Evaluasi mencakup jumlah frequent itemset dan aturan asosiasi, waktu eksekusi berulang, penggunaan memori puncak, sensitivitas parameter, serta skalabilitas pada beberapa ukuran dataset. Kualitas aturan juga dievaluasi menggunakan support, confidence, lift ratio, leverage, conviction, dan cosine similarity. Aturan yang memenuhi kriteria selanjutnya diinterpretasikan menjadi rekomendasi bundling menu bagi Selaras Coffee and Space. Dengan demikian, kebaruan penelitian tidak berupa pengembangan algoritma baru, tetapi berupa evaluasi yang lebih komprehensif dan penerjemahan hasil komputasi menjadi rekomendasi bisnis yang dapat diterapkan.

Penelitian ini bertujuan untuk mengidentifikasi pola pembelian pelanggan pada Selaras Coffee and Space dan mengevaluasi kinerja algoritma Apriori, FP-Growth, serta ECLAT dalam menghasilkan rekomendasi bundling menu. Ketiga algoritma diuji menggunakan dataset, tahapan preprocessing, nilai parameter, serta lingkungan perangkat keras dan perangkat lunak yang sama. Evaluasi dilakukan berdasarkan jumlah frequent itemset dan aturan asosiasi, waktu eksekusi, penggunaan memori, skalabilitas pada beberapa ukuran dataset, serta sensitivitas terhadap perubahan minimum support dan minimum confidence. Kualitas aturan dianalisis menggunakan support, confidence, lift ratio, leverage, conviction, dan cosine similarity. Aturan yang memenuhi kriteria kelayakan selanjutnya diinterpretasikan untuk menghasilkan rekomendasi bundling menu berdasarkan pola transaksi aktual. Hasil penelitian diharapkan dapat memberikan dasar yang lebih terukur bagi Selaras Coffee and Space dalam menyusun strategi bundling sekaligus

memberikan gambaran mengenai karakteristik kinerja ketiga algoritma pada data transaksi usaha kafe.

II. METODE

Penelitian ini menerapkan pendekatan *data mining* melalui teknik *association rule mining* untuk mengidentifikasi pola pembelian konsumen dari data transaksi penjualan. Proses analisis dilakukan menggunakan algoritma Apriori, FP-Growth, dan ECLAT pada dataset serta parameter pengujian yang sama. Ketiga algoritma kemudian dibandingkan berdasarkan jumlah *frequent itemset*, jumlah *association rule*, waktu eksekusi, serta kualitas aturan yang diukur menggunakan nilai *support*, *confidence*, dan *lift ratio*. Aturan asosiasi yang memenuhi kriteria evaluasi selanjutnya digunakan sebagai dasar dalam menyusun rekomendasi *bundling* menu pada Selaras Coffee and Space.

A. Objek dan Dataset Penelitian

Objek penelitian ini adalah Selaras Coffee and Space, yaitu usaha di bidang makanan dan minuman yang berlokasi di Kudus. Dataset diperoleh dari laporan detail transaksi pada sistem point of sale Selaras Coffee and Space selama periode 1-31 Desember 2025. File laporan memuat 14.758 baris setelah baris header, yang terdiri atas 14.754 baris detail penjualan dan empat baris ringkasan laporan yang bukan merupakan transaksi. Setelah empat baris tersebut dikeluarkan, data mencakup 6.213 transaksi unik berdasarkan Bill Number. Kolom Bill Number digunakan sebagai identitas transaksi, sedangkan kolom Menu digunakan sebagai item dalam proses *association rule mining*.


Kemunculan menu yang sama lebih dari satu kali dalam satu transaksi diringkas menjadi satu pasangan transaksi-item karena analisis menggunakan representasi biner yang hanya menunjukkan ada atau tidaknya suatu menu. Proses tersebut menghasilkan 14.530 pasangan transaksi-item unik sebelum penyaringan item operasional. Sebanyak 950 pasangan transaksi-item yang terdiri atas 777 Ice (Package), 171 Hot (Package), dan dua Espresso (Package) dikeluarkan karena merepresentasikan atribut penyajian, bukan menu utama yang relevan untuk rekomendasi *bundling*. Penyaringan tersebut tidak menghapus transaksi karena setiap Bill Number tetap memiliki sedikitnya satu menu yang valid. Dataset akhir terdiri atas 13.580 pasangan transaksi-item, 6.213 transaksi, dan 76 menu unik. Setiap transaksi memuat rata-rata 2,19 menu unik dengan median dua menu dan rentang antara satu sampai 16 menu. Jumlah transaksi harian berkisar antara 122 dan 282 transaksi, dengan rata-rata 200,42 transaksi per hari. Kepadatan dataset sebesar 2,88% menunjukkan bahwa matriks transaksi bersifat jarang atau sparse.

B. Tahapan Penelitian

Penelitian dilaksanakan melalui tujuh tahapan, yaitu pengumpulan dan karakterisasi dataset, preprocessing, transformasi data, penerapan algoritma, pengujian kinerja, evaluasi aturan asosiasi, dan penyusunan rekomendasi

bundling menu. Tahap pertama dilakukan dengan mengumpulkan data transaksi Selaras Coffee and Space serta mengidentifikasi jumlah baris, transaksi unik, menu unik, distribusi jumlah item per transaksi, dan kepadatan dataset. Tahap preprocessing mencakup pemilihan atribut, penanganan nilai kosong, normalisasi penulisan nama menu, penggabungan kemunculan item yang sama dalam satu transaksi, dan penghapusan item operasional. Data yang telah dibersihkan kemudian dikelompokkan berdasarkan Bill Number dan ditransformasikan menjadi matriks biner.

Matriks transaksi yang sama digunakan sebagai masukan bagi Apriori, FP-Growth, dan ECLAT agar perbandingan dilakukan secara terkontrol. Pengujian mencakup analisis sensitivitas terhadap perubahan minimum support dan minimum confidence, pengukuran waktu eksekusi secara berulang, penggunaan memori puncak, serta skalabilitas pada beberapa ukuran dataset. Frequent itemset dan aturan asosiasi yang dihasilkan selanjutnya dievaluasi menggunakan support, confidence, lift ratio, leverage, conviction, dan cosine similarity. Aturan yang memenuhi kriteria evaluasi diinterpretasikan berdasarkan hubungan antara antecedent dan consequent, kemudian digunakan sebagai dasar penyusunan rekomendasi *bundling* menu pada Selaras Coffee and Space. Keseluruhan tahapan penelitian ditunjukkan pada Gambar 1.



Gambar 1 Tahapan Penelitian

C. Preprocessing Data

Preprocessing diawali dengan membaca file laporan transaksi dan mengidentifikasi kolom yang berfungsi sebagai ID transaksi dan nama item. Pada dataset penelitian, Bill Number digunakan sebagai ID transaksi dan Menu digunakan sebagai item. Kriteria inklusi meliputi baris yang memiliki Bill Number dan nama menu yang tidak kosong serta tercatat pada periode 1-31 Desember 2025. Empat baris ringkasan pada bagian akhir laporan tidak memiliki Bill Number dan

bukan merupakan data penjualan sehingga dikeluarkan dari proses analisis. Setelah tahap tersebut, diperoleh 14.754 baris detail penjualan yang mewakili 6.213 transaksi unik.

Nama menu dibersihkan dengan menghapus spasi pada awal dan akhir teks, menyatukan spasi berlebih, serta menyeragamkan kapitalisasi agar variasi penulisan tidak dikenali sebagai item yang berbeda. Kemunculan menu yang sama lebih dari satu kali pada Bill Number yang sama kemudian diringkas menjadi satu pasangan transaksi-item. Langkah ini diperlukan karena association rule mining menggunakan keberadaan item dalam suatu transaksi, bukan jumlah unit yang dibeli. Sebanyak 224 kemunculan berulang diringkas sehingga diperoleh 14.530 pasangan transaksi-item unik.

Tahap berikutnya adalah mengeluarkan item yang namanya berakhiran "(Package)". Item tersebut terdiri atas 777 Ice (Package), 171 Hot (Package), dan dua Espresso (Package), dengan total 950 pasangan transaksi-item. Item package dikeluarkan karena merepresentasikan pilihan penyajian atau atribut produk, bukan menu utama yang relevan untuk rekomendasi bundling. Tidak ada transaksi yang dikeluarkan pada tahap ini karena seluruh Bill Number masih memiliki sedikitnya satu menu valid. Hasil preprocessing terdiri atas 13.580 pasangan transaksi-item yang mencakup 6.213 transaksi dan 76 menu unik. Data kemudian dikelompokkan berdasarkan Bill Number sehingga setiap transaksi berisi himpunan menu yang dibeli bersama dan siap ditransformasikan menjadi matriks biner.

D. Transformasi Data

Data hasil preprocessing dikelompokkan berdasarkan Bill Number sehingga setiap transaksi direpresentasikan sebagai himpunan menu yang dibeli secara bersamaan. Himpunan transaksi kemudian ditransformasikan menjadi matriks biner berukuran 6.213×76 , dengan 6.213 baris yang merepresentasikan transaksi dan 76 kolom yang merepresentasikan menu unik. Nilai $x_{ij} = 1$ diberikan apabila menu ke-j terdapat pada transaksi ke-i, sedangkan $x_{ij} = 0$ menunjukkan bahwa menu tersebut tidak terdapat dalam transaksi. Jika menu yang sama dibeli lebih dari satu kali dalam satu transaksi, nilainya tetap direpresentasikan sebagai 1 karena analisis berfokus pada keberadaan item, bukan kuantitas pembelian.

$$\text{Kepadatan} = \frac{\sum_{i=1}^N \sum_{j=1}^M x_{ij}}{N \times M} \times 100\% \quad \text{Equation 1}$$

Keterangan:

- x_{ij} = keberadaan menu ke-j pada transaksi ke-i;
- N = jumlah transaksi, yaitu 6.213;
- M = jumlah menu unik, yaitu 76.

Matriks biner memiliki 13.580 nilai aktif dari 472.188 kemungkinan pasangan transaksi-menu sehingga menghasilkan kepadatan dataset sebesar 2,88%. Nilai tersebut menunjukkan bahwa sebagian besar menu hanya muncul pada

sebagian kecil transaksi dan karakteristik matriks cenderung jarang atau sparse. Matriks biner yang sama digunakan sebagai masukan Apriori dan FP-Growth. Pada ECLAT, setiap kolom menu diubah secara internal menjadi TID-set yang memuat kumpulan indeks transaksi tempat menu tersebut muncul. Support kombinasi item kemudian dihitung melalui operasi irisan antarkumpulan TID-set. Penggunaan sumber data dan representasi awal yang sama dilakukan untuk menjaga konsistensi perbandingan ketiga algoritma.

E. Penerapan Algoritma Apriori, FP-Growth, dan ECLAT

Apriori, FP-Growth, dan ECLAT dijalankan menggunakan matriks transaksi, minimum support, dan minimum confidence yang sama. Suatu itemset dinyatakan frequent apabila proporsi kemunculannya memenuhi minimum support. Pada minimum support 0,01 dan jumlah transaksi sebanyak 6.213, itemset harus muncul pada sedikitnya $[0,01 \times 6.213] = 63$ transaksi. Penggunaan batas dan sumber data yang sama memastikan bahwa perbedaan hasil pengujian berasal dari mekanisme pemrosesan setiap algoritma, bukan dari perbedaan data atau parameter.

Apriori diterapkan menggunakan fungsi apriori pada pustaka mlxtend dengan proses pembentukan dan penyaringan kandidat itemset berdasarkan minimum support [4]. FP-Growth diterapkan menggunakan fungsi fpgrowth pada pustaka yang sama dengan membentuk FP-Tree untuk menelusuri pola tanpa menghasilkan kandidat secara eksplisit [5]. ECLAT diimplementasikan menggunakan pendekatan data vertikal. Setiap menu disimpan sebagai TID-set yang berisi indeks transaksi tempat menu tersebut muncul. Frequent itemset diperoleh secara rekursif melalui operasi irisan TID-set, kemudian hasilnya disaring berdasarkan jumlah minimum kemunculan [6], [7]. Frequent itemset dari ketiga algoritma selanjutnya dikonversi ke struktur yang sama untuk membentuk aturan asosiasi berdasarkan minimum confidence dan menyaring aturan dengan lift ratio lebih dari 1.

Secara teoretis, ketiga algoritma memiliki ruang pencarian yang dapat meningkat secara eksponensial terhadap jumlah menu karena kemungkinan itemset dapat mencapai $(2^m - 1)$, dengan (m) sebagai jumlah item unik. Apriori memiliki biaya tambahan dari pembentukan kandidat dan pemindaian berulang, terutama ketika minimum support rendah. FP-Growth mengurangi pembentukan kandidat melalui kompresi transaksi dalam FP-Tree, tetapi memerlukan waktu dan memori untuk membangun serta menelusuri struktur tersebut. Pada ECLAT, biaya komputasi terutama berasal dari operasi irisan dan penyimpanan TID-set. Oleh karena itu, tidak ada satu algoritma yang selalu paling efisien untuk seluruh dataset karena kinerjanya dipengaruhi oleh jumlah transaksi, jumlah item, kepadatan data, dan nilai minimum support yang digunakan.

F. Evaluasi Association Rule

Aturan asosiasi dinyatakan dalam bentuk $A \rightarrow B$, dengan A sebagai *antecedent* dan B sebagai *consequent*. Seleksi

utama dilakukan menggunakan minimum support dan minimum confidence, kemudian aturan disaring berdasarkan lift ratio lebih dari 1. Support menunjukkan proporsi transaksi yang memuat (A) dan (B), confidence menunjukkan kemungkinan (B) muncul pada transaksi yang telah memuat (A), sedangkan lift ratio membandingkan hubungan tersebut dengan kemungkinan kemunculan (B) secara independen. Untuk memperoleh evaluasi kualitas yang lebih komprehensif, penelitian ini juga menghitung leverage, conviction, dan cosine similarity. Ketiga metrik tambahan tersebut digunakan untuk memperkuat interpretasi aturan, bukan sebagai syarat utama untuk menghapus aturan.

$$\text{Support}(A \rightarrow B) = \frac{n(A \cup B)}{N} \quad \text{Equation 2}$$

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

$$\text{Lift}(A \rightarrow B) = \frac{\text{Confidence}(A \rightarrow B)}{\text{Support}(B)} \quad \text{Equation 4}$$

$$L(A \rightarrow B) = S(A \cup B) - S(A) \times S(B) \quad \text{Equation 5}$$

$$\text{Conviction}(A \rightarrow B) = \frac{1 - \text{Support}(B)}{1 - \text{Confidence}(A \rightarrow B)} \quad \text{Equation 6}$$

$$\text{Cosine}(A, B) = \frac{\text{Support}(A \cup B)}{\sqrt{\text{Support}(A) \times \text{Support}(B)}} \quad \text{Equation 7}$$

Lift ratio lebih dari 1 menunjukkan hubungan positif antara antecedent dan consequent. Leverage bernilai positif menunjukkan bahwa kedua item muncul bersama lebih sering daripada yang diharapkan apabila keduanya bersifat independen. Conviction lebih dari 1 menunjukkan adanya kekuatan implikasi positif dari antecedent menuju consequent, sedangkan nilai 1 menunjukkan hubungan yang mendekati independen. Cosine similarity memiliki rentang antara 0 dan 1, dengan nilai yang semakin mendekati 1 menunjukkan hubungan kemunculan bersama yang semakin kuat.

TABEL I
PARAMETER EVALUASI PENELITIAN

Parameter	Fungsi
Leverage	Mengukur selisih kemunculan aktual dengan kemunculan yang diharapkan
Conviction	Mengukur kekuatan implikasi aturan dengan mempertimbangkan kegagalan consequent
Cosine Similarity	Mengukur kesamaan kemunculan dua item setelah dinormalisasi berdasarkan support masing-masing
Penggunaan Memori	Mengukur penggunaan memori puncak selama eksekusi algoritma
Skalabilitas	Mengukur perubahan kinerja pada ukuran dataset yang berbeda

Tabel I menunjukkan parameter evaluasi yang digunakan dalam penelitian. Selain nilai *support*, *confidence*, dan *lift ratio* untuk menilai kualitas aturan asosiasi, penelitian ini juga membandingkan jumlah *frequent itemset*, jumlah *association rule*, dan waktu eksekusi untuk mengetahui performa masing-masing algoritma.

G. Skenario Pengujian

Pengujian dirancang dalam empat skenario, yaitu analisis sensitivitas parameter, pengukuran waktu dan penggunaan memori, pengujian skalabilitas, serta evaluasi kualitas aturan. Seluruh algoritma dijalankan menggunakan tahapan preprocessing dan lingkungan komputasi yang sama. Analisis sensitivitas menggunakan kombinasi minimum support sebesar 0,005, 0,010, 0,015, dan 0,020 dengan minimum confidence sebesar 0,15, 0,20, 0,25, dan 0,30. Setiap kombinasi digunakan untuk mengamati perubahan jumlah frequent itemset, jumlah aturan asosiasi, serta kualitas aturan yang dihasilkan.

Kombinasi minimum support 0,01 dan minimum confidence 0,20 digunakan sebagai skenario dasar. Nilai support tersebut mensyaratkan suatu itemset muncul pada sedikitnya 63 dari 6.213 transaksi, sedangkan confidence 0,20 mensyaratkan consequent muncul pada sedikitnya 20% transaksi yang memuat antecedent. Pemilihan parameter dasar dilakukan untuk menjaga keseimbangan antara frekuensi kemunculan pola dan jumlah aturan yang dapat diinterpretasikan. Analisis sensitivitas digunakan untuk memastikan bahwa pemilihan parameter tidak hanya bergantung pada satu kombinasi nilai.

Pengukuran waktu eksekusi dilakukan sebanyak 30 kali untuk setiap algoritma pada skenario dasar. Nilai yang dilaporkan meliputi rata-rata, standar deviasi, waktu minimum, dan waktu maksimum. Penggunaan memori puncak juga diukur selama proses pencarian frequent itemset dan pembentukan aturan asosiasi. Pengulangan diperlukan karena perbedaan waktu eksekusi ketiga algoritma relatif kecil dan dapat dipengaruhi oleh proses yang berjalan pada sistem operasi.

Pengujian skalabilitas dilakukan menggunakan 25%, 50%, 75%, dan 100% transaksi. Pengambilan subset dilakukan berdasarkan Bill Number sehingga seluruh menu dalam transaksi terpilih tetap dipertahankan. Pemilihan transaksi dilakukan secara acak dengan seed tetap sebesar 42 agar subset dapat direproduksi. Setiap algoritma menggunakan subset dan parameter yang sama. Perubahan waktu eksekusi dan penggunaan memori diamati untuk mengetahui respons algoritma terhadap peningkatan ukuran dataset.

TABEL II
SKENARIO PENGUJIAN ALGORITMA

Skenario	Pengaturan Pengujian	Evaluasi
Sensitivitas	Support 0,005-0,020; confidence 0,15-0,30	Itemset, aturan, dan kualitas aturan

Waktu dan memori	100% data; parameter dasar; 30 kali	Rata-rata, standar deviasi, dan memori puncak
Skalabilitas	25%, 50%, 75%, dan 100% data; 30 kali	Waktu dan penggunaan memori
Kualitas aturan	100% data; parameter dasar	Enam metrik kualitas aturan

H. Implementasi Sistem Pendukung

Sistem pendukung dibangun berbasis web menggunakan Laravel 12.62.0 dan PHP 8.2.4 sebagai aplikasi utama, sedangkan Python 3.13.3 digunakan sebagai engine pemrosesan association rule mining. Laravel menangani unggah dataset dalam format CSV, XLS, atau XLSX, input minimum support dan minimum confidence, penyimpanan riwayat analisis, serta penyajian hasil melalui dashboard. Sistem tidak menerapkan pembagian peran pengguna karena seluruh fungsi analisis diakses melalui satu antarmuka yang sama. Pemisahan antara antarmuka web dan engine komputasi digunakan agar proses pengelolaan data dan perhitungan algoritma dapat dijalankan secara terstruktur [17]-[19].

Setelah pengguna mengunggah dataset dan menentukan parameter, Laravel menjalankan skrip Python melalui Symfony Process. Python melakukan preprocessing, membentuk matriks biner, menjalankan Apriori, FP-Growth, dan ECLAT, serta menghitung metrik evaluasi. Hasil pemrosesan dikembalikan kepada Laravel dalam format JSON dan ditampilkan pada dashboard. MySQL digunakan untuk menyimpan informasi dan hasil ringkas setiap analisis, sedangkan file dataset dan keluaran JSON disimpan pada direktori penyimpanan Laravel. Dataset transaksi yang diunggah tidak disimpan secara permanen sebagai tabel di dalam basis data.

Eksperimen dijalankan pada HP Laptop 14s-fq2xxx dengan sistem operasi Microsoft Windows 11 Home Single Language 64-bit. Perangkat menggunakan prosesor AMD Ryzen 5 5625U berkecepatan 2,30 GHz dengan enam core fisik, 12 logical processor, dan RAM 16 GB. Pemrosesan data dilakukan menggunakan Pandas 3.0.3 dan mlxtend 0.25.0. Seluruh algoritma dijalankan pada lingkungan perangkat keras dan perangkat lunak yang sama. Waktu eksekusi diukur menggunakan perf_counter mulai dari proses pencarian frequent itemset hingga pembentukan dan penyaringan aturan asosiasi. Pengukuran tersebut tidak mencakup proses unggah dataset, preprocessing awal, pembentukan matriks biner, penyimpanan JSON, maupun penyajian hasil pada dashboard.


III. HASIL DAN PEMBAHASAN

Bagian ini menyajikan hasil penerapan dan evaluasi algoritma Apriori, FP-Growth, dan ECLAT pada 6.213 transaksi yang mencakup 76 menu unik. Ketiga algoritma diuji menggunakan dataset, tahapan preprocessing, parameter, dan lingkungan komputasi yang sama agar perbandingan dilakukan secara terkontrol. Evaluasi

mencakup kesesuaian frequent itemset dan aturan asosiasi, sensitivitas minimum support dan minimum confidence, waktu eksekusi dan penggunaan memori, skalabilitas terhadap perubahan ukuran dataset, serta kualitas aturan berdasarkan support, confidence, lift ratio, leverage, conviction, dan cosine similarity. Aturan yang memenuhi kriteria kelayakan selanjutnya diinterpretasikan sebagai dasar penyusunan rekomendasi bundling menu bagi Selaras Coffee and Space.

A. Persiapan dan Karakteristik Dataset

Data transaksi penelitian berasal dari sistem point of sale Selaras Coffee and Space selama periode 1–31 Desember 2025. File laporan awal memuat 14.758 baris setelah header, yang terdiri atas 14.754 baris detail penjualan dan empat baris ringkasan laporan yang bukan merupakan transaksi. Setelah empat baris tersebut dikeluarkan, sebanyak 224 kemunculan menu yang berulang pada Bill Number yang sama diringkas sehingga diperoleh 14.530 pasangan transaksi-item unik. Tahap berikutnya mengeluarkan 950 pasangan transaksi-item operasional yang terdiri atas 777 Ice (Package), 171 Hot (Package), dan dua Espresso (Package) karena item tersebut merepresentasikan atribut penyajian, bukan menu utama. Hasil preprocessing menghasilkan 13.580 pasangan transaksi-item yang mencakup 6.213 transaksi dan 76 menu unik. Tidak ada transaksi yang dihapus karena setiap Bill Number masih memiliki sedikitnya satu menu yang valid. Ringkasan proses pembersihan tersebut ditunjukkan pada Gambar 2.



Gambar 2 Proses Preprocessing dan Pembersihan Data pada Sistem

Data hasil preprocessing kemudian dikelompokkan berdasarkan Bill Number dan ditransformasikan menjadi matriks biner berukuran 6.213×76 , dengan baris merepresentasikan transaksi dan kolom merepresentasikan menu unik. Setiap transaksi memuat rata-rata 2,19 menu unik, dengan median dua menu serta rentang antara satu hingga 16 menu. Jumlah transaksi harian berkisar antara 122 dan 282 transaksi, dengan rata-rata 200,42 transaksi per hari. Matriks biner memuat 13.580 nilai aktif dari 472.188 kemungkinan pasangan transaksi-menu sehingga menghasilkan kepadatan sebesar 2,88%. Nilai kepadatan tersebut menunjukkan bahwa data bersifat jarang atau sparse karena sebagian besar menu hanya muncul pada sebagian kecil transaksi. Matriks yang

sama digunakan sebagai masukan bagi Apriori, FP-Growth, dan ECLAT agar perbandingan hasil ketiga algoritma dilakukan secara konsisten.

B. Pengujian dan Pembentukan Association Rule

Skenario dasar menggunakan minimum support sebesar 0,01, minimum confidence sebesar 0,20, dan lift ratio lebih dari 1. Minimum support 0,01 mensyaratkan itemset muncul pada sedikitnya 63 dari 6.213 transaksi, sedangkan minimum confidence 0,20 mensyaratkan consequent muncul pada sedikitnya 20% transaksi yang memuat antecedent. Pemilihan parameter tersebut didasarkan pada hasil analisis sensitivitas. Pada minimum support 0,005 dan minimum confidence 0,20 diperoleh 131 frequent itemset dan 12 aturan layak, sedangkan peningkatan minimum support menjadi 0,015 dengan minimum confidence yang sama tidak menghasilkan aturan layak. Kombinasi minimum support 0,01 dan minimum confidence 0,20 menghasilkan 68 frequent itemset dan lima aturan layak sehingga dipilih sebagai titik tengah yang menjaga cakupan pola sekaligus menghasilkan jumlah aturan yang dapat diinterpretasikan untuk rekomendasi bundling menu.

Pada skenario dasar, Apriori, FP-Growth, dan ECLAT menghasilkan 68 frequent itemset dan lima kandidat aturan dengan hasil yang identik. Seluruh kandidat memenuhi minimum confidence sebesar 0,20 dan memiliki lift ratio lebih dari 1 sehingga dinyatakan sebagai aturan layak. Frequent 1-itemset dengan support tertinggi adalah Kopi Susu Gula Aren sebesar 0,179462 atau muncul pada sekitar 17,95% transaksi, diikuti Mix Platter sebesar 0,125382 danAmericano sebesar 0,121841. Hasil tersebut menunjukkan bahwa ketiga algoritma mampu menemukan pola frekuensi dan aturan asosiasi yang konsisten pada dataset dan nilai ambang yang sama.

Kesamaan frequent itemset dan aturan asosiasi terjadi karena ketiga algoritma menggunakan definisi support serta kriteria kelayakan yang sama pada matriks transaksi yang identik. Apriori, FP-Growth, dan ECLAT hanya menggunakan mekanisme pencarian yang berbeda, tetapi masing-masing dirancang untuk menemukan seluruh itemset yang memenuhi minimum support. Frequent itemset yang ditemukan kemudian diproses menggunakan minimum confidence dan penyaringan lift ratio yang sama sehingga aturan akhirnya juga identik. Oleh karena itu, perbedaan ketiga algoritma pada penelitian ini tidak terletak pada pola yang dihasilkan, melainkan pada waktu eksekusi, penggunaan memori, dan respons terhadap peningkatan ukuran dataset.

C. Perbandingan Waktu Eksekusi dan Penggunaan Memori

Meskipun menghasilkan frequent itemset dan aturan asosiasi yang identik, ketiga algoritma menunjukkan perbedaan efisiensi komputasi. Pengukuran dilakukan sebanyak 30 kali pada dataset penuh menggunakan minimum support 0,01 dan minimum confidence 0,20. Waktu eksekusi dihitung mulai dari proses pencarian frequent itemset hingga pembentukan dan penyaringan aturan, sedangkan

penggunaan memori diukur sebagai alokasi memori puncak Python menggunakan tracemalloc. Ringkasan hasil pengujian disajikan pada Tabel III.

TABEL III
PERBANDINGAN HASIL DAN EFISIENSI KOMPUTASI

Metrik	Apriori	FP-Growth	ECLAT
Jumlah frequent itemset	68	68	68
Jumlah aturan layak	5	5	5
Runtime rata-rata (detik)	0,040419	0,069637	0,037701
Standar deviasi runtime	0,001976	0,004628	0,003786
Runtime minimum (detik)	0,038048	0,062355	0,034746
Runtime maksimum (detik)	0,047163	0,086644	0,051098
Rata-rata memori puncak (MB)	20,978426	1,026966	1,133289
Memori puncak tertinggi (MB)	20,978426	1,026983	1,136363

Berdasarkan Tabel III, ECLAT memperoleh runtime rata-rata terendah pada dataset penuh, yaitu 0,037701 detik, diikuti Apriori sebesar 0,040419 detik dan FP-Growth sebesar 0,069637 detik. Pada kondisi pengujian ini, ECLAT sekitar 6,72% lebih cepat daripada Apriori dan 45,86% lebih cepat daripada FP-Growth. Apriori memiliki standar deviasi runtime paling rendah sebesar 0,001976 detik, sedangkan FP-Growth dan ECLAT masing-masing memiliki standar deviasi sebesar 0,004628 dan 0,003786 detik. Hasil 30 pengulangan tersebut menunjukkan bahwa perbedaan rata-rata waktu tidak hanya berasal dari satu kali proses eksekusi.

Runtime ECLAT yang lebih rendah pada dataset penuh dapat dikaitkan dengan representasi vertikal TID-set yang memungkinkan pencarian kombinasi item dilakukan melalui operasi irisan kumpulan transaksi. Karakteristik dataset yang jarang, dengan kepadatan 2,88% dan rata-rata 2,19 menu per transaksi, membuat ukuran TID-set relatif terbatas. Apriori memiliki runtime yang mendekati ECLAT karena jumlah kombinasi yang memenuhi minimum support juga relatif sedikit, sedangkan FP-Growth memerlukan tahapan pembentukan dan penelusuran FP-Tree yang pada dataset ini belum memberikan keuntungan waktu dibandingkan biaya pembentukannya. Keunggulan ECLAT tersebut sejalan dengan penelitian sebelumnya yang menunjukkan bahwa representasi data vertikal dapat meningkatkan efisiensi pencarian frequent itemset [6], [7], [12]. Namun, FP-Growth yang lebih lambat daripada Apriori memperlihatkan bahwa efisiensi struktur FP-Tree tetap dipengaruhi oleh ukuran, kepadatan, dan distribusi transaksi [4], [5], [13], [14].

Dari sisi penggunaan memori, FP-Growth mencatat rata-rata memori puncak terendah sebesar 1,026966 MB, diikuti ECLAT sebesar 1,133289 MB, sedangkan Apriori memerlukan 20,978426 MB. Dengan demikian, penggunaan memori Apriori sekitar 20,43 kali lebih besar daripada FP-Growth dan 18,51 kali lebih besar daripada ECLAT.

Perbedaan tersebut berkaitan dengan pembentukan kandidat dan struktur antara yang digunakan Apriori selama proses pencarian itemset. Pengukuran menggunakan tracemalloc merepresentasikan alokasi memori puncak Python selama eksekusi algoritma dan tidak mencakup keseluruhan penggunaan RAM sistem. Hasil ini menunjukkan adanya kompromi kinerja: ECLAT memberikan waktu rata-rata terendah pada dataset penuh, sedangkan FP-Growth memberikan penggunaan memori paling rendah.

D. Analisis Sensitivitas Parameter

Analisis sensitivitas dilakukan menggunakan 16 kombinasi minimum support dan minimum confidence untuk mengetahui perubahan jumlah frequent itemset dan aturan asosiasi. Ketiga algoritma menghasilkan jumlah itemset dan aturan yang sama pada setiap kombinasi parameter karena menggunakan dataset dan kriteria evaluasi yang identik. Oleh karena itu, hasil ketiga algoritma disajikan satu kali pada Tabel IV tanpa mengulang baris untuk setiap algoritma.

TABEL IV
HASIL ANALISIS SENSITIVITAS PARAMETER

Min Support	Min Confidence	Frequent Itemset	Kandidat Aturan	Aturan Layak
0,005	0,15	131	29	26
0,005	0,20	131	12	12
0,005	0,25	131	3	3
0,005	0,30	131	0	0
0,010	0,15	68	12	10
0,010	0,20	68	5	5
0,010	0,25	68	1	1
0,010	0,30	68	0	0
0,015	0,15	44	1	1
0,015	0,20	44	0	0
0,015	0,25	44	0	0
0,015	0,30	44	0	0
0,020	0,15	34	1	1
0,020	0,20	34	0	0
0,020	0,25	34	0	0
0,020	0,30	34	0	0

Tabel IV menunjukkan bahwa penurunan minimum support meningkatkan jumlah frequent itemset yang ditemukan. Pada minimum support 0,005 diperoleh 131 frequent itemset, sedangkan nilai tersebut menurun menjadi 68, 44, dan 34 ketika minimum support dinaikkan masing-masing menjadi 0,010, 0,015, dan 0,020. Pada minimum confidence tetap sebesar 0,20, jumlah aturan layak juga menurun dari 12 aturan pada minimum support 0,005 menjadi lima aturan pada minimum support 0,010, kemudian tidak ada aturan yang memenuhi kriteria pada minimum support 0,015 dan 0,020. Hasil tersebut menunjukkan bahwa peningkatan minimum support menyaring kombinasi menu yang memiliki frekuensi kemunculan lebih rendah.

Perubahan minimum confidence tidak memengaruhi jumlah frequent itemset karena nilai tersebut digunakan setelah proses pencarian itemset, tetapi secara langsung

memengaruhi jumlah aturan yang terbentuk. Pada minimum support 0,010, peningkatan minimum confidence dari 0,15 menjadi 0,20, 0,25, dan 0,30 menurunkan jumlah aturan layak dari 10 menjadi lima, satu, dan nol aturan. Kombinasi minimum support 0,010 dan minimum confidence 0,20 dipilih karena mampu mengurangi pola berfrekuensi rendah yang lebih banyak muncul pada minimum support 0,005, tetapi tetap mempertahankan lima aturan yang dapat diinterpretasikan. Temuan ini mendukung penelitian sebelumnya bahwa nilai minimum support dan minimum confidence perlu disesuaikan dengan ukuran serta distribusi transaksi karena menentukan jumlah pola dan aturan yang dihasilkan [15], [16].

E. Analisis Skalabilitas

Pengujian skalabilitas dilakukan untuk mengamati perubahan waktu eksekusi dan penggunaan memori ketika jumlah transaksi ditingkatkan. Dataset dibagi menjadi subset bertingkat sebesar 25%, 50%, 75%, dan 100% menggunakan seed tetap 42, sehingga setiap subset yang lebih besar mencakup transaksi pada subset sebelumnya. Apriori, FP-Growth, dan ECLAT dijalankan sebanyak 30 kali pada setiap ukuran data menggunakan minimum support 0,01 dan minimum confidence 0,20. Rata-rata waktu eksekusi dan memori puncak masing-masing algoritma disajikan pada Tabel V.

TABEL V
HASIL PENGUJIAN SKALABILITAS ALGORITMA

Data	Transaksi	Algoritma	Runtime Rata-rata (detik)	Memori Puncak Rata-rata (MB)
25%	1.553	Apriori	0,024707	5,264008
25%	1.553	FP-Growth	0,029267	0,408281
25%	1.553	ECLAT	0,027631	0,305874
50%	3.106	Apriori	0,028346	10,073687
50%	3.106	FP-Growth	0,042994	0,649181
50%	3.106	ECLAT	0,030437	0,630770
75%	4.660	Apriori	0,033242	15,100664
75%	4.660	FP-Growth	0,058348	0,834770
75%	4.660	ECLAT	0,034810	0,867141
100%	6.213	Apriori	0,040419	20,978426
100%	6.213	FP-Growth	0,069637	1,026966
100%	6.213	ECLAT	0,037701	1,133289

Tabel V menunjukkan bahwa waktu eksekusi ketiga algoritma meningkat seiring bertambahnya jumlah transaksi. Apriori mencatat runtime rata-rata terendah pada subset 25%, 50%, dan 75%, masing-masing sebesar 0,024707, 0,028346, dan 0,033242 detik. Pada penggunaan 100% data, ECLAT menjadi algoritma tercepat dengan runtime rata-rata 0,037701 detik, dibandingkan Apriori sebesar 0,040419 detik dan FP-Growth sebesar 0,069637 detik. Hasil tersebut menunjukkan bahwa keunggulan algoritma dapat berubah mengikuti ukuran dataset sehingga ECLAT tidak dapat dinyatakan selalu paling cepat pada setiap kondisi pengujian.

Jika dibandingkan dari subset 25% hingga 100%, runtime Apriori meningkat sekitar 63,59%, FP-Growth meningkat 137,93%, sedangkan ECLAT hanya meningkat 36,45%. Pertumbuhan runtime ECLAT yang paling rendah menunjukkan bahwa pendekatan TID-set mampu mempertahankan efisiensi waktu dengan lebih baik ketika jumlah transaksi ditingkatkan. Sebaliknya, FP-Growth mengalami peningkatan runtime terbesar karena biaya pembentukan dan penelusuran FP-Tree ikut bertambah seiring peningkatan ukuran dataset. Hasil ini memperkuat temuan penelitian sebelumnya bahwa performa relatif Apriori, FP-Growth, dan ECLAT dipengaruhi oleh ukuran serta karakteristik data yang diproses [6], [7], [12]-[14].

Penggunaan memori Apriori meningkat hampir sebanding dengan ukuran dataset, yaitu dari 5,264008 MB pada subset 25% menjadi 20,978426 MB pada data penuh. FP-Growth menggunakan memori rata-rata sebesar 0,408281–1,026966 MB, sedangkan ECLAT menggunakan 0,305874–1,133289 MB. ECLAT mencatat penggunaan memori terendah pada subset 25% dan 50%, tetapi FP-Growth menjadi yang terendah pada subset 75% dan 100%. Dengan demikian, hasil skalabilitas menunjukkan kompromi yang berbeda: Apriori memiliki waktu terendah pada subset kecil hingga menengah, ECLAT menunjukkan pertumbuhan runtime paling rendah, sedangkan FP-Growth lebih hemat memori pada ukuran data yang lebih besar.

F. Analisis Kualitas Aturan dan Rekomendasi Bundling

Kelima aturan asosiasi yang dihasilkan Apriori, FP-Growth, dan ECLAT memiliki nilai yang identik sehingga hasilnya disajikan satu kali tanpa mengulang tabel untuk setiap algoritma. Seluruh aturan memenuhi minimum support 0,01, minimum confidence 0,20, dan lift ratio lebih dari 1. Evaluasi tidak hanya menggunakan support, confidence, dan lift ratio, tetapi juga leverage, conviction, serta cosine similarity agar kekuatan setiap aturan dapat dianalisis secara lebih komprehensif. Metrik utama disajikan pada Tabel VI, sedangkan metrik tambahan disajikan pada Tabel VII agar tabel tetap terbaca dalam format dua kolom.

TABEL VI
NILAI SUPPORT, CONFIDENCE, DAN LIFT ATURAN ASOSIASI

No	Aturan Asosiasi	Support	Confidence	Lift Ratio
1	Mie Laksa → Air Mineral 330 Ml	0,010140	0,255061	2,755987
2	Red Velvet → Mix Platter	0,012232	0,214085	1,707454
3	Kopi Susu Regal → Kopi Susu Gula Aren	0,012393	0,209809	1,169099
4	Nasi Goreng Selaras → Lychee Tea	0,013359	0,209596	1,912217
5		0,010140	0,200000	1,114439

	French Fries → Kopi Susu Gula Aren			
--	------------------------------------	--	--	--

TABEL VII
NILAI LEVERAGE, CONVICTION, DAN COSINE SIMILARITY

No. Aturan	Leverage	Conviction	Cosine Similarity
1	0,006461	1,218156	0,167170
2	0,005068	1,112865	0,144521
3	0,001793	1,038404	0,120371
4	0,006373	1,126501	0,159830
5	0,001041	1,025672	0,106304



NO	JIKA MEMBELI	DIREKOMENDASIKAN	SUPPORT	CONFIDENCE	LIFT
1	Mie Laksa	Air Mineral 330 Ml	0.010140	0.255061	2.755987
2	Red Velvet	Mix Platter	0.012232	0.214085	1.707454
3	Kopi Susu Regal	Kopi Susu Gula Aren	0.012393	0.209809	1.169099
4	Nasi Goreng Selaras	Lychee Tea	0.013359	0.209596	1.912217
5	French Fries	Kopi Susu Gula Aren	0.010140	0.200000	1.114439

Gambar 3 Tampilan Aturan Asosiasi ECLAT pada Sistem

Karena ketiga algoritma menghasilkan aturan yang identik, tampilan hasil ECLAT digunakan sebagai contoh keluaran sistem sebagaimana ditunjukkan pada Gambar 3.

Berdasarkan Tabel VI dan Tabel VII, aturan Mie Laksa → Air Mineral 330 Ml memiliki lift ratio tertinggi sebesar 2,755987. Aturan tersebut muncul pada 63 transaksi dengan support 0,010140 dan confidence 0,255061, yang berarti sekitar 25,51% transaksi yang memuat Mie Laksa juga memuat Air Mineral 330 Ml. Lift ratio tersebut menunjukkan bahwa kemunculan Air Mineral 330 Ml pada transaksi yang memuat Mie Laksa sekitar 2,76 kali lebih tinggi dibandingkan frekuensi dasarnya pada seluruh transaksi. Nilai leverage sebesar 0,006461, conviction sebesar 1,218156, dan cosine similarity sebesar 0,167170 juga merupakan nilai tertinggi di antara lima aturan sehingga memperkuat indikasi hubungan positif pada kombinasi tersebut.

Aturan Nasi Goreng Selaras → Lychee Tea memiliki support tertinggi sebesar 0,013359 atau muncul pada 83 transaksi, dengan confidence 0,209596 dan lift ratio 1,912217. Aturan Red Velvet → Mix Platter memiliki lift ratio 1,707454, sedangkan Kopi Susu Regal → Kopi Susu Gula Aren dan French Fries → Kopi Susu Gula Aren masing-masing memiliki lift ratio 1,169099 dan 1,114439. Seluruh aturan memiliki leverage positif dan conviction lebih dari 1, yang menunjukkan bahwa kemunculan bersama setiap pasangan menu lebih tinggi daripada kondisi independen. Meskipun kekuatan hubungannya berbeda, kelima aturan tetap dapat dipertimbangkan sebagai kandidat rekomendasi karena memenuhi seluruh kriteria kelayakan.

Dalam penerapan bisnis, Mie Laksa dan Air Mineral 330 ml dapat ditawarkan sebagai paket makanan dan minuman, sedangkan Nasi Goreng Selaras dan Lychee Tea dapat digunakan sebagai alternatif paket utama. Kombinasi Red Velvet dan Mix Platter dapat diterapkan sebagai promosi berbagi, sementara Kopi Susu Gula Aren dapat direkomendasikan sebagai penawaran tambahan ketika pelanggan memilih Kopi Susu Regal atau French Fries. Rekomendasi tersebut dapat diterapkan melalui paket pada daftar menu, penempatan menu yang berdekatan, saran otomatis pada sistem kasir, atau potongan harga terbatas. Besaran harga dan diskon perlu disesuaikan kembali dengan margin keuntungan masing-masing menu karena informasi biaya tidak termasuk dalam dataset penelitian.

Aturan asosiasi menunjukkan keterkaitan pola pembelian, tetapi tidak membuktikan hubungan sebab-akibat ataupun menjamin peningkatan penjualan. Oleh karena itu, penerapan rekomendasi sebaiknya diuji secara terbatas dengan membandingkan jumlah pembelian paket, nilai rata-rata transaksi, dan penjualan menu sebelum serta sesudah promosi. Pengujian operasional tersebut diperlukan untuk mengetahui apakah rekomendasi berbasis pola historis benar-benar memberikan dampak bisnis pada kondisi nyata.

G. Keterbatasan Penelitian

Penelitian ini menggunakan data transaksi dari satu lokasi usaha selama periode 1–31 Desember 2025. Oleh karena itu, aturan asosiasi yang diperoleh merepresentasikan pola pembelian pada periode dan lokasi tersebut serta belum dapat digeneralisasi untuk cabang, periode, atau jenis usaha lain. Perubahan musim, hari libur, program promosi, harga, dan ketersediaan menu juga dapat memengaruhi pola transaksi dari waktu ke waktu. Pengujian skalabilitas dilakukan menggunakan subset bertingkat dari dataset yang sama dengan ukuran maksimum 6.213 transaksi sehingga hasilnya belum menggambarkan kinerja algoritma pada dataset yang jauh lebih besar atau memiliki tingkat kepadatan berbeda.

Pengukuran memori menggunakan tracemalloc hanya mencatat alokasi memori Python selama proses algoritma dan tidak merepresentasikan keseluruhan penggunaan RAM sistem. Waktu eksekusi juga dipengaruhi oleh spesifikasi perangkat keras dan perangkat lunak yang digunakan. Selain itu, dataset tidak memuat informasi biaya, margin keuntungan, identitas pelanggan, ketersediaan bahan, maupun respons pelanggan terhadap paket yang direkomendasikan. Penelitian ini belum melakukan uji operasional untuk mengukur dampak bundling terhadap penjualan. Penelitian selanjutnya dapat menggunakan data dengan periode lebih panjang dan beberapa lokasi, membandingkan algoritma association rule lainnya, serta melakukan uji coba promosi untuk mengevaluasi perubahan jumlah pembelian paket, nilai transaksi, dan keuntungan.

IV. KESIMPULAN

Penelitian ini berhasil mengidentifikasi pola pembelian pelanggan dan mengevaluasi kinerja Apriori, FP-Growth, dan ECLAT untuk mendukung rekomendasi bundling menu pada Selaras Coffee and Space. Setelah preprocessing, diperoleh 13.580 pasangan transaksi-item yang mencakup 6.213 transaksi dan 76 menu unik, dengan kepadatan matriks sebesar 2,88%. Pada minimum support 0,01, minimum confidence 0,20, dan lift ratio lebih dari 1, ketiga algoritma menghasilkan 68 frequent itemset dan lima aturan asosiasi yang identik. Kesamaan tersebut terjadi karena ketiga algoritma menggunakan dataset dan kriteria kelayakan yang sama, sedangkan perbedaannya terletak pada mekanisme pencarian itemset.

Aturan Mie Laksa → Air Mineral 330 ml memiliki kekuatan hubungan tertinggi dengan support 0,010140, confidence 0,255061, lift ratio 2,755987, leverage 0,006461, conviction 1,218156, dan cosine similarity 0,167170. Kelima aturan yang diperoleh dapat digunakan sebagai dasar awal dalam menyusun paket menu, penempatan menu, penawaran tambahan pada sistem kasir, dan promosi terbatas. Namun, aturan tersebut menunjukkan keterkaitan pola pembelian dan belum membuktikan hubungan sebab-akibat atau peningkatan penjualan sehingga dampaknya masih perlu diuji dalam lingkungan operasional.

Hasil evaluasi menunjukkan bahwa tidak ada satu algoritma yang unggul pada seluruh aspek. Pada dataset penuh, ECLAT memperoleh runtime rata-rata terendah sebesar 0,037701 detik, diikuti Apriori sebesar 0,040419 detik dan FP-Growth sebesar 0,069637 detik. Apriori lebih cepat pada subset 25–75%, sedangkan ECLAT memiliki pertumbuhan runtime paling rendah sebesar 36,45% ketika ukuran data ditingkatkan dari 25% menjadi 100%. FP-Growth mencatat penggunaan memori terendah pada data penuh sebesar 1,026966 MB, sedangkan Apriori menggunakan 20,978426 MB. Analisis sensitivitas menunjukkan bahwa kombinasi minimum support 0,01 dan minimum confidence 0,20 memberikan keseimbangan antara cakupan pola dan jumlah aturan yang dapat diinterpretasikan. Temuan tersebut menegaskan bahwa pemilihan algoritma perlu disesuaikan dengan karakteristik dataset dan prioritas penggunaan, yaitu kecepatan, skalabilitas, atau efisiensi memori.

DAFTAR PUSTAKA

- [1] R. P. Aditya, N. Wanti, and W. Sari, "Rekomendasi Paket Menu Pada Cafe Abc Berbasis Website Implementation Of Apriori Algorithm For Menu Package Recommendations At Cafe Abc Based On Websites," vol. 11, no. 2, 2023.
- [2] T. Kurniana, A. Lestari, and E. D. Oktaviyani, "Penerapan Algoritma Apriori untuk Mencari Pola Transaksi Penjualan Berbasis Web pada Cafe Sakuyan Side," vol. 3, no. 1, pp. 13–23, 2023.
- [3] Y. Muharmi and W. A. Pulungan, "E ISSN : 2809-4069 Analisis Pola Transaksi Penjualan Untuk Rekomendasi Menu Menggunakan Algoritma Apriori," vol. 5, no. 2, pp. 265–273, 2025.
- [4] S. R. Karimah and E. D. Udayanti, "Comparison of Apriori and FP-

- Growth Algorithms in Market Basket Analysis for Online Book Sales,” vol. 10, no. 1, pp. 566–574, 2026.
- [5] D. Dwiputra, A. M. Widodo, H. Akbar, G. Firmansyah, and U. E. Unggul, “Evaluating The Performance Of Association Rules In Apriori And Fp-Growth Algorithms : Market Basket Analysis To Discoverrules Of Item Combinations,” vol. 2, no. 8, pp. 1229–1248, 2023, doi: 10.58344/jws.v2i8.403.
- [6] dan A. N. Pujiharto, Kusriani, “Comparative Analysis of The Performance of The Apriori, FP-Growth and Eclat Algorithms In Finding Frequency Patterns In The Ina-Cbg’s Dataset,” vol. 9, no. 2, pp. 340–354, 2023.
- [7] R. Wahyuningsih, A. Suharsono, and N. Iriawan, “Comparison Of Market Basket Analysis Method Using Apriori Algorithm , Frequent Pattern Growth (Fp- Growth) And Equivalence Class Transformation (Eclat) (Case Study : Supermarket ‘ X ’ Transaction Data For 2021),” pp. 192–201, 2021.
- [8] S. Marselina, J. H. Jaman, and D. E. Kurniawan, “Sales Analysis Using Apriori Algorithm in Data Mining Application on Food and Beverage (F & B) Transactions,” vol. 7, no. 2, pp. 218–223, 2023.
- [9] I. G. Ngurah, B. Picessa, K. Mandala, I. K. A. Purnawan, I. M. Agus, and D. Suarjaya, “Implementation of FP-Growth Algorithms for Promo Package Determination in a Scooter Motorcycle Workshop Business,” vol. 9, no. 3, pp. 756–764, 2025.
- [10] S. R. Bagaskara and D. H. Bangkalang, “Analisis dan Implementasi Market Basket Analysis (MBA) Menggunakan Algoritma Apriori dengan Dukungan Visualisasi Data,” vol. 4, pp. 612–620, 2023, doi: 10.30865/json.v4i4.6351.
- [11] M. H. Nasri, G. Y. Pratama, R. Hammad, and I. N. Switrayana, “Integrasi Association Rule Mining dan Cost-Plus Pricing untuk Optimasi Paket Produk dan Profitabilitas UMKM,” vol. 11, no. 1, pp. 48–56, 2026.
- [12] Y. Husain, E. D. Oktaviyani, and S. Christina, “Analisis Perbandingan Algoritma Apriori, FP-Growth, dan Eclat dalam Menemukan Pola Pembelian Konsumen,” vol. 3, no. 2, pp. 231–243, 2023.
- [13] A. D. Ardiani, M. P. Kein, S. Marfiah, and N. Wanti, “Perbandingan Algoritma Apriori dan FP- Growth dalam Menemukan Pola Asosiasi pada Data Penjualan Produk Ritel di Toko IT Data Mining,” vol. 5, no. April, 2026.
- [14] R. A. Putra, M. Amalia, M. Putri, and S. M. Sinaga, “Implementation of Association Rules Algorithm to Identify Popular Topping Combinations in Orders,” vol. 1, no. January, pp. 95–101, 2024.
- [15] D. Alfitra, M. Afdal, M. Fronita, and E. Saputra, “Analisa Keranjang Belanja untuk Menentukan Tata Letak Barang Menggunakan Algoritma FP-Growth Market Basket Analysis for Determine Goods Layout Using FP-Growth Algorithm,” vol. 13, pp. 1651–1661, 2024.
- [16] G. T. Alfaridzi, F. N. Salisah, and I. Permana, “Application of Apriori and FP-Growth Algorithms in Analyzing Drug Purchasing Patterns,” vol. 5, no. 1, pp. 128–134, 2026.
- [17] A. C. Simanjuntak, M. E. Sitanggang, and M. Indah, “Penerapan Metode Data Mining Market Basket Analysis Terhadap Data Penjualan Produk Pada Toko Iblite Luxury Menggunakan Algoritma Apriori,” no. 3, 2024.
- [18] A. J. Purwanto, A. Setiawan, and N. Latifah, “Penerapan UCD dalam Sistem Peminjaman Barang dan Ruangan Dengan Laravel,” vol. 5, pp. 7061–7074, 2025.
- [19] A. Z. Mubarak and N. Latifah, “Decision Support System Internet Disruption Using ORESTE and Geolocation PT Cloud Solution,” vol. 18, no. 2, pp. 915–927, 2025.