

Implementasi Algoritma FP-Growth untuk Sistem Rekomendasi Produk Kebutuhan Pokok pada *E-Commerce*

Mahjid Herlambang¹, Susanto¹

¹. Program Studi Teknik Informatika, Universitas Semarang, Indonesia

* Korespondensi: mahjidherlambang24@gmail.com

Sitasi: M. Herlambang and S. Susanto, "Implementasi Algoritma FP-Growth untuk Sistem Rekomendasi Produk Kebutuhan Pokok pada E-Commerce", *Jurnal Teknologi Informasi dan Multimedia*, vol. 8, no. 1, pp. 169-184, 2026.
<https://doi.org/10.35746/jtim.v8i1.900>

Diterima: 26-11-2025

Direvisi: 20-01-2026

Disetujui: 02-02-2026



Copyright: © 2026 oleh para penulis. Karya ini dilisensikan di bawah Creative Commons Attribution-ShareAlike 4.0 International License. (<https://creativecommons.org/licenses/by-sa/4.0/>).

Abstract: The rapid development of e-commerce in Indonesia necessitates recommendation systems that can capture user purchasing patterns accurately, adaptively, and in a data-driven manner. This study implements the FP-Growth algorithm to analyze transaction data from a self-developed essential-goods e-commerce platform. The research dataset consists of 60 user accounts with a total of 600 completed transactions, processed using a Python-based analytical module and automatically integrated into a Laravel backend through a dedicated execution script. The FP-Growth algorithm is applied to generate frequent itemsets and association rules using a minimum support of 0.01, a minimum confidence of 0.1, and a minimum lift of 1.0. The results indicate that the most dominant associative patterns occur among kitchen staple products such as instant noodles, chicken eggs, and wheat flour, as well as household cleaning products such as detergents and fabric softeners. Several rules exhibit confidence values as high as 0.9615 and lift values up to 4.451, indicating strong and statistically significant relationships between products. System performance evaluation using a Top-4 recommendation scheme shows a Hit Rate of 54.35% and a Recall of 54.35%, demonstrating that the system is able to provide relevant recommendations for the majority of transactions. This implementation is shown to improve recommendation accuracy while strengthening personalization and cross-selling strategies on essential-goods e-commerce platforms. These findings confirm that FP-Growth is an effective and efficient method for identifying empirical purchasing patterns and supporting the development of recommendation systems in small- to medium-scale e-commerce environments.

Keywords: FP-Growth; recommendation system; e-commerce; association rule mining; frequent itemset.

Abstrak: Perkembangan pesat *e-commerce* di Indonesia menuntut adanya sistem rekomendasi yang mampu menangkap pola pembelian pengguna secara akurat, adaptif, dan berbasis data. Penelitian ini mengimplementasikan algoritma FP-Growth untuk menganalisis transaksi pada platform *e-commerce* kebutuhan pokok yang dikembangkan secara mandiri. Dataset penelitian terdiri atas 60 akun pengguna dengan total 600 transaksi *completed*, yang diproses menggunakan modul analisis berbasis Python dan terintegrasi secara otomatis ke *backend* Laravel melalui skrip pemanggil khusus. Algoritma FP-Growth digunakan untuk menghasilkan *frequent itemset* dan *association rules* berdasarkan parameter minimum *support* 0,01, *minimum confidence* 0,1, dan *minimum lift* 1,0. Hasil penelitian menunjukkan bahwa pola keterkaitan yang paling dominan muncul pada kelompok produk dapur seperti mie instan, telur ayam, dan tepung terigu, serta pada produk kebersihan rumah tangga seperti deterjen dan pewangi pakaian. Beberapa aturan menunjukkan nilai *confidence* hingga 0,9615 dan nilai *lift* mencapai 4,451, yang menandakan hubungan kuat dan signifikan antarproduk dalam perilaku belanja pengguna. Evaluasi kinerja sistem menggunakan skema *Top-4 Recommendation* menunjukkan nilai *Hit Rate* sebesar 54.35% dan *Recall* sebesar 54.35%, yang membuktikan bahwa sistem

mampu memberikan rekomendasi relevan pada mayoritas transaksi. Implementasi ini terbukti meningkatkan akurasi rekomendasi serta memperkuat potensi personalisasi dan strategi *cross-selling* pada platform *e-commerce* kebutuhan pokok. Temuan ini menegaskan bahwa FP-Growth merupakan metode yang efektif dan efisien untuk mengidentifikasi pola pembelian empiris serta mendukung pengembangan sistem rekomendasi pada lingkungan *e-commerce* berskala kecil hingga menengah.

Kata kunci: FP-Growth; sistem rekomendasi; *e-commerce*; *association rule mining*; *frequent itemset*.

1. Pendahuluan

Perkembangan teknologi informasi telah memberikan pengaruh besar terhadap ekspansi sektor *e-commerce* di Indonesia. Fenomena ini tidak hanya dipicu oleh kemudahan dalam melakukan transaksi daring, tetapi juga oleh meningkatnya kebutuhan masyarakat terhadap efisiensi waktu dan personalisasi dalam berbelanja. Pertumbuhan jumlah pengguna internet serta intensitas transaksi digital setiap tahunnya menjadikan *e-commerce* sebagai salah satu pilar penting dalam transformasi ekonomi nasional [1]. Meski demikian, tantangan utama yang dihadapi platform *e-commerce* terletak pada kemampuan memahami perilaku konsumen secara mendalam agar dapat menyajikan rekomendasi produk yang sesuai dengan preferensi dan pola pembelian mereka [2]. Dalam konteks penjualan kebutuhan pokok secara daring yang melibatkan banyak varian produk, ketiadaan fitur rekomendasi otomatis menyebabkan proses penemuan produk (*product discovery*) menjadi tidak efisien, di mana pengguna sering kali harus mencari produk pelengkap secara manual satu per satu.

Sistem rekomendasi memiliki peran strategis dalam memperkuat interaksi pengguna, meningkatkan potensi transaksi, serta membangun loyalitas pelanggan terhadap platform *e-commerce* [3]. Salah satu pendekatan populer yang digunakan untuk menganalisis perilaku pembelian konsumen ialah *market basket analysis*, yang berfokus pada identifikasi keterkaitan antarproduk berdasarkan kebiasaan pembelian bersamaan [3]. Algoritma FP-Growth (*Frequent Pattern Growth*) merupakan metode yang efektif dalam penerapan analisis ini karena mampu menemukan *frequent itemset* tanpa proses pembangkitan kandidat seperti pada algoritma Apriori [4]. Keunggulan FP-Growth terletak pada efisiensinya dalam memproses data berukuran besar dengan memanfaatkan struktur FP-Tree yang mampu mengompresi data transaksi tanpa mengurangi makna atau informasi penting [5].

Beragam studi sebelumnya telah menunjukkan penerapan FP-Growth dalam konteks sistem rekomendasi *e-commerce* [6]. Fairuzindah [7] membuktikan bahwa algoritma ini mampu mengidentifikasi pola belanja konsumen pada platform *e-commerce* lokal, meskipun implementasinya masih bersifat analitis dan belum terintegrasi secara dinamis dalam sistem rekomendasi. Foster [8] turut mengaplikasikan FP-Growth pada sistem rekomendasi produk batik berbasis web, namun cakupan pengujiannya masih terbatas pada jumlah transaksi yang relatif kecil. Sebaliknya, Siam [9] mengungkapkan bahwa penggunaan FP-Growth dalam *association rule mining* dapat meningkatkan efektivitas strategi pemasaran personal serta mendorong perilaku pembelian berulang dalam skala besar.

Penelitian ini menawarkan kebaruan berupa penerapan langsung algoritma FP-Growth pada sistem *e-commerce* kebutuhan pokok yang telah dikembangkan. Perbedaan utama dengan penelitian sebelumnya terletak pada proses integrasi hasil aturan asosiasi ke dalam basis data rekomendasi (*product recommendations*) secara otomatis melalui modul komputasi berbasis Python yang terhubung dengan *backend e-commerce*. Dataset

yang digunakan berasal dari simulasi realistis yang terdiri atas 60 akun pengguna dengan total 600 transaksi “completed,” sehingga mampu merepresentasikan pola belanja konsumen secara autentik [10]. Pendekatan ini diharapkan mampu menghasilkan rekomendasi yang lebih relevan, adaptif terhadap perubahan perilaku pembelian, serta siap diimplementasikan pada sistem *e-commerce* secara nyata.

Oleh karena itu, penelitian ini bertujuan untuk mengimplementasikan algoritma FP-Growth dalam sistem rekomendasi produk kebutuhan pokok yang terintegrasi dengan platform *e-commerce*, serta mengevaluasi kinerja dan efektivitasnya dalam menghasilkan rekomendasi produk yang sesuai dengan pola transaksi pengguna.

2. Bahan dan Metode

Penelitian ini menggunakan metode eksperimen terapan dengan pendekatan kuantitatif, di mana algoritma FP-Growth diimplementasikan secara langsung pada sistem *e-commerce* kebutuhan pokok yang telah dikembangkan. Melalui pendekatan ini, peneliti dapat mengamati hasil nyata dari penerapan algoritma terhadap data transaksi pengguna, sekaligus mengevaluasi efektivitasnya dalam menghasilkan rekomendasi produk yang relevan berdasarkan pola keterkaitan antaritem. Pendekatan eksperimental ini tidak hanya menekankan pada pengujian teknis, tetapi juga pada kemampuan sistem untuk beradaptasi dengan dinamika perilaku pengguna dalam lingkungan transaksi digital yang sesungguhnya.

Pemilihan metode eksperimen kuantitatif didasarkan pada relevansinya terhadap tujuan penelitian yang menekankan validasi kinerja algoritma dalam konteks sistem operasional. Hasil implementasi dapat diukur secara objektif menggunakan parameter numerik seperti *support*, *confidence*, dan *lift*, yang menggambarkan tingkat kekuatan hubungan antarproduk serta akurasi rekomendasi yang dihasilkan. Penggunaan metrik tersebut memberikan dasar empiris yang kuat untuk menilai sejauh mana algoritma FP-Growth mampu mendukung pengambilan keputusan dalam sistem rekomendasi produk kebutuhan pokok secara terukur dan dapat dipertanggungjawabkan.



Gambar 1. Diagram alur penelitian

Proses penelitian ini dilaksanakan melalui serangkaian tahapan yang disusun secara sistematis sebagaimana ditunjukkan pada Gambar 1. Tahapan tersebut mencakup: (1) pengumpulan data transaksi pengguna sebagai dasar pembentukan pola pembelian, (2) pra-pemrosesan data untuk memastikan konsistensi, kelengkapan, dan kesiapan dataset sebelum dianalisis, (3) penerapan algoritma FP-Growth untuk menghasilkan *frequent itemset* dan *association rules*, (4) integrasi otomatis hasil analisis ke dalam modul rekomendasi pada sistem *e-commerce*, serta (5) validasi dan evaluasi kinerja sistem rekomendasi. Setiap tahap dirancang untuk memastikan alur analisis berjalan efisien dan mendukung pembentukan rekomendasi yang dapat diimplementasikan secara langsung dalam lingkungan operasional.

Tahap validasi dilakukan dengan memverifikasi kesesuaian antara aturan asosiasi yang dihasilkan dan pola transaksi aktual dalam dataset. Verifikasi ini memastikan bahwa aturan yang terbentuk memiliki relevansi empiris terhadap perilaku pembelian pengguna. Selanjutnya, tahap evaluasi difokuskan pada pengujian efektivitas sistem rekomendasi melalui pengamatan relevansi produk yang muncul pada halaman rekomendasi *e-commerce*, baik pada laman *product detail* maupun *checkout*. Pendekatan bertingkat ini menjamin bahwa sistem tidak hanya berfungsi secara teknis, tetapi juga mampu memberikan rekomendasi yang benar-benar selaras dengan preferensi dan kebiasaan belanja pengguna.

2.1 Dataset dan Proses Generasi Data

Penelitian ini menggunakan dataset sintetis berbasis skenario (*scenario-based synthetic data*) yang dirancang untuk mengatasi permasalahan *cold-start* pada sistem rekomendasi yang baru dikembangkan. Dataset terdiri dari 600 transaksi berstatus “*completed*” yang merepresentasikan aktivitas belanja pengguna pada platform e-commerce kebutuhan pokok. Seluruh transaksi tersebut melibatkan 50 produk unik (*Stock Keeping Unit/SKU*) yang dikelompokkan ke dalam 5 kategori utama, yaitu bahan makanan pokok, makanan *instan*, bumbu dapur, produk kebersihan rumah tangga dan minuman.

Pembangkitan dataset dilakukan dengan mempertahankan karakteristik distribusi frekuensi item bertipe *long-tail*, di mana sebagian kecil produk memiliki frekuensi kemunculan yang tinggi, sementara sebagian besar produk lainnya muncul dengan frekuensi lebih rendah. Pola ini dimodelkan berdasarkan *domain knowledge* perilaku belanja UMKM dan rumah tangga, khususnya pada e-commerce kebutuhan pokok, di mana produk konsumsi harian seperti telur ayam, mie instan, dan bahan pokok lainnya cenderung memiliki tingkat pembelian berulang yang lebih tinggi.

Setiap transaksi dirancang memiliki rata-rata 3 hingga 5 item per keranjang belanja, dengan distribusi kombinasi item yang mencerminkan hubungan komplementer antarproduk, seperti kombinasi bahan memasak dan produk pendukung. Pembentukan kombinasi item dilakukan secara terkontrol untuk memastikan kemunculan pola asosiasi deterministik, sehingga data sintetis yang dihasilkan tetap memiliki struktur dan keterkaitan yang realistis untuk dianalisis menggunakan algoritma FP-Growth.

Penggunaan dataset sintetis yang tervalidasi secara struktural dipilih karena dataset publik yang tersedia, seperti pada platform *Kaggle*, umumnya merepresentasikan ritel modern berskala besar dengan karakteristik pola belanja yang berbeda dari konteks UMKM dan e-commerce kebutuhan pokok yang menjadi fokus penelitian ini. Oleh karena itu, dataset sintetis digunakan untuk memastikan kesesuaian konteks data dengan tujuan penelitian, sekaligus memungkinkan pengendalian terhadap distribusi pola pembelian yang dianalisis.

2.2 Alat dan Lingkungan Pengembangan

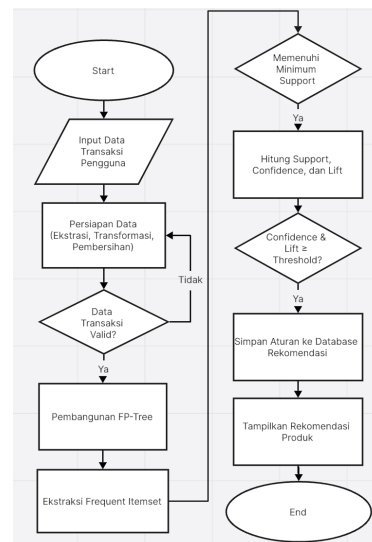
Sistem rekomendasi produk pada penelitian ini dikembangkan dalam dua lingkungan utama yang saling terintegrasi, yaitu backend e-commerce dan modul FP-Growth. Bagian backend dibangun menggunakan Laravel Framework versi 10 dengan bahasa pemrograman PHP 8.2, yang berfungsi untuk mengelola seluruh proses transaksi, manajemen produk, serta penyimpanan data hasil rekomendasi pengguna [11]. Sementara itu, modul analisis pola transaksi dikembangkan menggunakan Python 3.11 dengan bantuan pustaka *mlxtend*, yang menyediakan pustaka untuk pembangkitan frequent itemset dan aturan asosiasi untuk mendeteksi hubungan antarproduk berdasarkan frekuensi kemunculan dalam transaksi pengguna.

Integrasi antara kedua komponen tersebut dilakukan melalui skrip backend controller yang bertugas memanggil modul analisis Python secara langsung. Proses ini memungkinkan pertukaran data secara dinamis, di mana hasil analisis asosiasi dikembalikan dalam format JSON kemudian disimpan ke dalam tabel *product_recommendations* pada basis data sistem. Konfigurasi tersebut dipilih untuk memastikan kestabilan, efisiensi komputasi, dan kemampuan sistem dalam menangani proses analisis data secara real-time.

2.3 Implementasi Algoritma FP-Growth

Sistem rekomendasi yang dikembangkan dalam penelitian ini dirancang menggunakan arsitektur *client-server* berbasis web, di mana proses pengolahan data dan eksekusi algoritma dilakukan secara terpisah namun terintegrasi. Pada sisi server, *framework* Laravel berfungsi sebagai pengelola utama yang menangani manajemen data,

otentikasi pengguna, serta pengaturan alur logika aplikasi. Sementara itu, bahasa pemrograman Python digunakan untuk menjalankan algoritma FP-Growth yang bertugas menganalisis data transaksi guna menemukan pola asosiasi antarproduk. Integrasi antara Laravel dan Python diimplementasikan melalui perintah *Artisan Command*, yang memungkinkan eksekusi skrip analisis secara otomatis tanpa perlu intervensi manual, sehingga meningkatkan efisiensi serta sinkronisasi data antarproses. Integrasi antar komponen tersebut membentuk alur proses analisis data transaksi yang terstruktur, yang divisualisasikan dalam bentuk *flowchart* sebagaimana ditunjukkan pada Gambar 2.



Gambar 2. Flowchart proses analisis FP-Growth dalam sistem rekomendasi

Gambar 2 menunjukkan alur proses analisis FP-Growth yang digunakan dalam penelitian ini, dimulai dari input data transaksi, tahap persiapan data, pembentukan FP-Tree, hingga proses seleksi *frequent itemset* dan pembentukan aturan asosiasi berdasarkan nilai *support*, *confidence*, dan *lift*. Alur keputusan pada *flowchart* memperlihatkan bahwa hanya *itemset* dan aturan yang memenuhi ambang parameter yang telah ditetapkan yang diteruskan ke tahap penyimpanan dan integrasi ke dalam sistem rekomendasi, sedangkan aturan yang tidak memenuhi kriteria secara otomatis dieliminasi.

2.3.1 Formulasi Matematis FP-Growth

Perhitungan utama pada algoritma FP-Growth didasarkan pada tiga ukuran statistik, yaitu *support*, *confidence*, dan *lift*. Ketiga ukuran ini digunakan untuk mengukur tingkat keterkaitan antarproduk dalam data transaksi dan menjadi dasar pembentukan aturan asosiasi yang dimanfaatkan dalam sistem rekomendasi, sebagaimana dirumuskan pada Persamaan (1) hingga Persamaan (3) [12].

Ukuran pertama adalah *support*, yang menunjukkan seberapa sering suatu kombinasi item (*itemset*) muncul dalam keseluruhan transaksi. Nilai *support* dihitung dengan membandingkan jumlah transaksi yang mengandung *itemset* tertentu terhadap total jumlah transaksi, sebagaimana ditunjukkan pada Persamaan (1) [12].

$$Support(X) = \frac{n(X)}{N} \quad (1)$$

Keterangan:

- $n(X)$: jumlah transaksi yang mengandung *itemset* X
- N : jumlah total transaksi

Ukuran kedua adalah *confidence*, yang digunakan untuk menilai kekuatan hubungan antara dua item atau lebih dalam suatu aturan asosiasi. *Confidence* merepresentasikan

probabilitas kemunculan item Y setelah item X muncul dalam satu transaksi, sebagaimana dirumuskan pada Persamaan (2) [12].

$$Confidence(X \Rightarrow Y) = \frac{Support(X \cup Y)}{Support(X)} \quad (2)$$

Selanjutnya, *lift* digunakan untuk mengukur kekuatan hubungan antaritem dengan membandingkan nilai *confidence* terhadap peluang kemunculan item Y secara independen. Nilai *lift* memberikan indikasi apakah hubungan antaritem bersifat kebetulan atau menunjukkan korelasi yang signifikan, sebagaimana dirumuskan pada Persamaan (3) [12].

$$Lift(X \Rightarrow Y) = \frac{Support(X \cup Y)}{Support(X) \times Support(Y)} \quad (3)$$

Interpretasi dari ketiga ukuran tersebut adalah sebagai berikut, *support* merepresentasikan frekuensi kemunculan kombinasi item dalam dataset, *confidence* menunjukkan tingkat keandalan asosiasi antaritem, sedangkan *lift* menilai kekuatan hubungan antaritem. Nilai *lift* yang lebih besar dari 1 mengindikasikan adanya korelasi positif yang signifikan antaritem, sehingga aturan asosiasi tersebut layak dipertimbangkan dalam sistem rekomendasi [12].

2.3.2 Mekanisme FP-Growth dalam Menemukan Pola Keterkaitan Antarproduk

Algoritma FP-Growth bekerja dengan menganalisis frekuensi kemunculan item dalam transaksi pengguna tanpa memerlukan informasi tambahan mengenai kategori produk, seperti “bahan dapur” atau “minuman.” Dengan demikian, algoritma tidak memiliki pengetahuan eksplisit bahwa telur dan tepung termasuk bahan dapur, atau bahwa susu UHT merupakan produk minuman. Pola keterkaitan yang terbentuk antarproduk muncul secara murni melalui analisis *co-occurrence*, yaitu kecenderungan dua atau lebih item muncul secara bersamaan dalam transaksi yang sama. Pendekatan ini memungkinkan FP-Growth mengidentifikasi hubungan empiris berdasarkan perilaku pembelian aktual pengguna.

Proses dimulai dengan pembangunan FP-Tree, yaitu struktur pohon yang mengompresi seluruh data transaksi dengan menggabungkan jalur yang memiliki kombinasi item serupa. Item-item yang sering muncul bersama cenderung membentuk cabang yang sama, sehingga pola keterkaitan antarproduk terlihat secara alami melalui struktur pohon tersebut. Semakin tinggi frekuensi kemunculan dua item dalam transaksi yang sama, semakin kuat dan semakin jelas pola cabang yang terbentuk dalam FP-Tree.

Dari struktur FP-Tree, algoritma kemudian mengekstraksi *frequent itemset*, yakni kombinasi produk yang tingkat kemunculannya memenuhi nilai *minimum support*. Sebagai contoh, jika telur dan tepung sering dibeli secara bersamaan dalam sejumlah transaksi, maka keduanya akan diklasifikasikan sebagai *frequent itemset* meskipun tidak ada informasi kategori produk yang diberikan kepada sistem. Dengan cara ini, FP-Growth dapat menangkap hubungan implisit yang muncul dari kebiasaan belanja pengguna.

Tahap akhir adalah pembentukan aturan asosiasi yang mengevaluasi kekuatan hubungan antaritem menggunakan tiga metrik utama: *support*, *confidence*, dan *lift*. Nilai *confidence* menunjukkan probabilitas munculnya produk Y ketika produk X dibeli, sedangkan *lift* mengukur kekuatan hubungan tersebut dibandingkan peluang acak. *Lift* lebih besar dari 1 menandakan adanya keterkaitan signifikan antarproduk. Melalui mekanisme ini, FP-Growth dapat mengidentifikasi pola pembelian konsumen secara empiris dan menghasilkan rekomendasi produk yang relevan berdasarkan perilaku pengguna yang sesungguhnya.

2.3.3 Parameter Pengujian Algoritma FP-Growth

Parameter pengujian digunakan untuk menentukan ambang batas dalam proses pembentukan *frequent itemset* dan aturan asosiasi. Nilai setiap parameter berpengaruh langsung terhadap jumlah kombinasi produk yang terbentuk serta tingkat relevansi aturan yang dihasilkan oleh algoritma. Pada penelitian ini digunakan tiga parameter utama, yaitu *minimum support*, *minimum confidence*, dan *minimum lift*. Ketiga parameter tersebut ditetapkan dengan mempertimbangkan karakteristik dataset serta tujuan penelitian, yaitu menghasilkan aturan asosiasi yang relevan dan representatif terhadap pola pembelian pengguna, sebagaimana dirincikan pada Tabel 2.

Tabel 2. Parameter pengujian algoritma FP-Growth

Parameter	Nilai	Deskripsi
<i>Minimum Support</i>	0.01	Ambang minimum kemunculan item
<i>Minimum Confidence</i>	0.1	Ambang kekuatan asosiasi
<i>Minimum Lift</i>	1.0	Indikator hubungan signifikansi

Pada Tabel 2. Nilai minimum support sebesar 0,01 dipilih karena dataset yang digunakan berukuran relatif kecil, yaitu 600 transaksi, sehingga ambang ini memungkinkan pola pembelian minor namun konsisten tetap terdeteksi. Nilai *minimum confidence* sebesar 0,1 digunakan untuk menjaga fleksibilitas pembentukan aturan asosiasi agar tidak terlalu ketat pada tahap awal seleksi, sedangkan nilai *minimum lift* sebesar 1,0 digunakan sebagai indikator dasar adanya hubungan positif antaritem, sesuai dengan praktik umum dalam *association rule mining*.

Penetapan nilai parameter tersebut memastikan bahwa hanya kombinasi produk dengan tingkat keterkaitan yang signifikan yang dipertahankan pada tahap pembentukan aturan asosiasi. Dengan demikian, hasil analisis FP-Growth yang diperoleh memiliki stabilitas yang lebih baik, tingkat relevansi yang tinggi, serta dapat diintegrasikan secara efektif ke dalam sistem rekomendasi produk pada platform *e-commerce*.

2.4 Skenario Pengujian dan Evaluasi Kinerja

Untuk mengukur efektivitas sistem rekomendasi secara objektif, penelitian ini menerapkan skema pengujian validasi silang menggunakan metode train-test split dengan rasio 80:20. Sebanyak 480 transaksi digunakan sebagai data latih (training set) untuk pembentukan aturan asosiasi, sedangkan 120 transaksi sisanya digunakan sebagai data uji (testing set). Pembagian ini bertujuan untuk memastikan bahwa aturan asosiasi yang dihasilkan mampu digeneralisasikan dengan baik pada data yang belum pernah dilihat sebelumnya.

Kualitas rekomendasi dievaluasi menggunakan metrik Precision@K, Recall@K, dan Hit Rate@K dengan nilai K = 4 (Top-4 recommendation). Pemilihan nilai K = 4 disesuaikan dengan batasan antarmuka pengguna (grid view) pada sistem *e-commerce* yang menampilkan maksimal empat produk rekomendasi dalam satu tampilan. Metrik evaluasi ini digunakan untuk menilai relevansi rekomendasi dari perspektif pengguna akhir, sehingga evaluasi tidak hanya didasarkan pada kekuatan pola asosiasi, tetapi juga pada kualitas rekomendasi yang diterima pengguna.

Nilai Precision@K digunakan untuk mengukur proporsi item relevan yang berhasil direkomendasikan pada posisi Top-K, sebagaimana dirumuskan pada Persamaan (4).

$$\text{Precision@K} = \frac{\text{Jumlah item relevan pada Top-K}}{K} \quad (4)$$

Sementara itu, Recall@K digunakan untuk mengukur kemampuan sistem dalam menemukan item relevan dari seluruh item yang seharusnya direkomendasikan, sebagaimana ditunjukkan pada Persamaan (5).

$$\text{Recall@K} = \frac{\text{Jumlah item relevan pada Top-K}}{\text{Total item relevan pada transaksi}} \quad (5)$$

Selain itu, metrik Hit Rate@K digunakan untuk mengukur proporsi transaksi uji di mana sistem berhasil memberikan setidaknya satu rekomendasi yang relevan kepada pengguna. Metrik ini dirumuskan pada Persamaan (6).

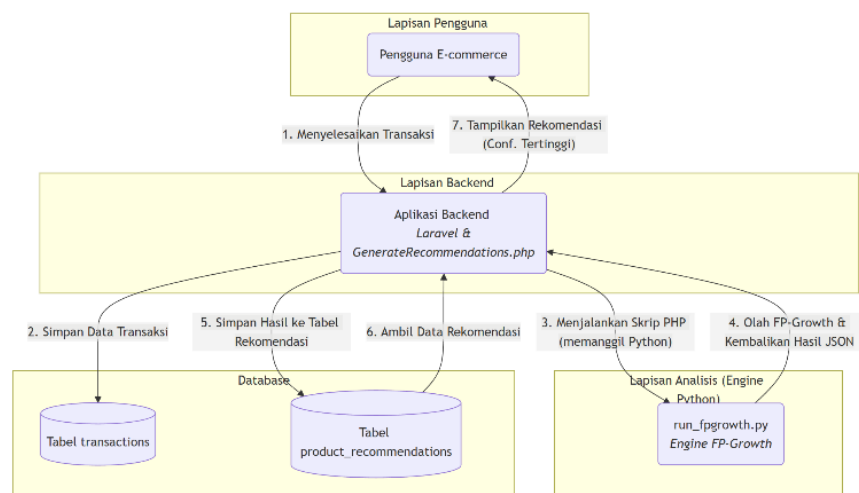
$$\text{Hit Rate@K} = \frac{\text{Jumlah transaksi dengan } \geq 1 \text{ rekomendasi relevan}}{\text{Total transaksi pengujian}} \quad (6)$$

Penggunaan kombinasi metrik Precision@K, Recall@K, dan Hit Rate@K memberikan gambaran yang lebih komprehensif mengenai kinerja sistem rekomendasi. Precision@K merepresentasikan ketepatan rekomendasi, Recall@K menunjukkan tingkat ketercakupan item relevan, sedangkan Hit Rate@K mencerminkan kemampuan sistem dalam memberikan rekomendasi yang bermanfaat pada tingkat transaksi. Dengan demikian, evaluasi yang dilakukan tidak hanya menilai kekuatan statistik aturan asosiasi, tetapi juga efektivitas sistem rekomendasi dalam konteks penggunaan nyata.

2.5 Integrasi Sistem Rekomendasi

Setelah aturan asosiasi terbentuk, sistem secara otomatis menampilkan rekomendasi produk kepada pengguna berdasarkan hasil analisis algoritma FP-Growth. Alur proses integrasi dimulai ketika pengguna berhasil menyelesaikan transaksi pada aplikasi e-commerce. Setelah transaksi dikonfirmasi, aplikasi backend berbasis Laravel menyimpan seluruh detail transaksi ke dalam tabel transactions pada basis data. Selanjutnya, sistem memicu eksekusi modul penghubung sistem, yang berfungsi sebagai penghubung antara modul backend dan lapisan analisis berbasis Python. Skrip PHP tersebut kemudian mengeksekusi engine algoritma FP-Growth, yang bertugas menjalankan algoritma FP-Growth untuk menganalisis data transaksi dan menghasilkan aturan asosiasi antarproduk berdasarkan pola pembelian pengguna.

Setelah proses analisis selesai dijalankan, hasil aturan asosiasi dikembalikan ke backend dalam format JSON yang berisi pasangan aturan antecedent → consequent beserta nilai confidence-nya. Backend kemudian memproses hasil tersebut dan menyimpannya ke dalam tabel product_recommendations. Ketika pengguna mengakses halaman tertentu, seperti halaman detail produk atau konfirmasi transaksi, sistem akan mengambil rekomendasi yang relevan dari tabel tersebut. Produk dengan nilai confidence tertinggi diprioritaskan untuk ditampilkan kepada pengguna melalui antarmuka e-commerce. Dengan mekanisme ini, sistem rekomendasi dapat bekerja secara dinamis dan real-time, memberikan saran produk yang paling sesuai dengan pola pembelian dan preferensi pengguna, sekaligus meningkatkan personalisasi pengalaman belanja secara keseluruhan. Arsitektur sistem rekomendasi yang dikembangkan dalam penelitian ini dirancang menggunakan pendekatan client-server dengan pemisahan proses pengolahan data dan antarmuka pengguna. Integrasi antara framework Laravel dan bahasa pemrograman Python dalam menjalankan algoritma FP-Growth ditunjukkan pada Gambar 3.



Gambar 3. Integrasi algoritma FP-Growth dalam arsitektur sistem *e-commerce*

Gambar 3 memperlihatkan arsitektur sistem rekomendasi berbasis web yang terdiri dari lapisan antarmuka pengguna, lapisan aplikasi, dan lapisan pemrosesan data. Pada sisi server, Laravel berperan sebagai pengelola alur aplikasi, autentikasi pengguna, serta manajemen data transaksi. Sementara itu, algoritma FP-Growth dieksekusi menggunakan Python yang terintegrasi melalui Artisan Command, sehingga proses analisis data transaksi dapat dijalankan secara otomatis dan terpisah dari antarmuka pengguna. Pendekatan ini memungkinkan sistem melakukan pembaruan rekomendasi secara efisien tanpa mengganggu performa layanan utama.

3. Hasil dan Pembahasan

Bab ini menyajikan hasil pengolahan data transaksi menggunakan algoritma FP-Growth serta implementasi aturan asosiasi dalam sistem rekomendasi produk kebutuhan pokok pada platform *e-commerce* yang telah dikembangkan. Seluruh proses analisis dilakukan pada dataset yang bersumber dari 60 akun pelanggan dengan total 600 transaksi berstatus completed. Data tersebut diproses melalui modul algoritma, yang berfungsi menjalankan algoritma FP-Growth secara langsung pada dataset aktual. Proses ini menghasilkan frequent itemset serta aturan asosiasi yang kemudian diintegrasikan ke dalam modul rekomendasi sistem.

3.1 Hasil Pembentukan Frequent Itemset

Tahap awal penerapan algoritma FP-Growth menghasilkan serangkaian frequent itemset berdasarkan nilai minimum support yang ditetapkan sebesar 1%. Nilai ini dipilih dengan mempertimbangkan distribusi frekuensi transaksi dalam dataset, sehingga hanya kombinasi item yang benar-benar menunjukkan pola pembelian berulang yang signifikan yang akan dipertahankan. Itemset yang melampaui ambang support tersebut dianggap memiliki tingkat relevansi tinggi dalam perilaku belanja pengguna dan menjadi dasar utama pembentukan aturan asosiasi pada tahap berikutnya.

Hasil analisis menunjukkan bahwa frequent itemset yang terbentuk didominasi oleh barang kebutuhan pokok dengan tingkat konsumsi tinggi dan stabil, seperti mie instan, telur ayam, tepung terigu, deterjen, dan pewangi pakaian. Pola ini mencerminkan karakteristik belanja rumah tangga yang bersifat berulang, di mana produk-produk tersebut cenderung dibeli secara konsisten dalam rentang waktu tertentu [13]. Selain itu, dominasi item kebutuhan dasar memperlihatkan bahwa perilaku pembelian pada *e-commerce* kebutuhan pokok cenderung terfokus pada produk sehari-hari yang memiliki frekuensi rotasi stok tinggi di tingkat rumah tangga.

Keberadaan itemset yang kuat pada produk tertentu juga mengindikasikan potensi keterkaitan antarproduk yang dapat dimanfaatkan dalam proses rekomendasi. Misalnya, kombinasi telur dengan tepung terigu atau mie instan dengan saus sambal mengindikasikan kebiasaan pembelian komplementer yang secara konsisten muncul dalam transaksi pengguna. Pola seperti ini penting untuk diidentifikasi karena berpotensi menghasilkan aturan asosiasi dengan nilai confidence dan lift yang tinggi, sehingga rekomendasi yang dihasilkan lebih relevan terhadap kebutuhan pengguna, sebagaimana dirincikan pada Tabel 3.

Tabel 3. Daftar aturan asosiasi terbaik berdasarkan hasil algoritma FP-Growth

No	Antecedent	Consequent	Support	Confidence	Lift
1	Molto Pink (820ml)	Molto Blue (820ml)	0.167	0.962	5.342
2	Sunlight Jeruk Nipis	Molto Blue (820ml)	0.167	0.901	5.005
3	Indomie Goreng Original	Telur Ayam Negeri	0.228	0.940	3.120
4	Saus Sambal ABC	Telur Ayam Negeri	0.195	0.925	3.410
5	Tepung Terigu Segitiga	Telur Ayam Negeri	0.190	0.905	2.850
6	Beras Premium (5kg)	Minyak Goreng (2l)	0.155	0.885	4.120
7	Kopi Kapal Api	Gula Pasir (1kg)	0.145	0.890	3.750
8	Sarden ABC	Telur Ayam Negeri	0.185	0.910	2.950
9	Susu Kental Manis	Roti Tawar	0.140	0.880	3.550
10	Molto Blue (820ml)	Sunlight Jeruk Nipis	0.167	0.926	5.005

Tabel 3 menyajikan daftar aturan asosiasi terbaik yang dihasilkan oleh algoritma FP-Growth berdasarkan ambang minimum support, confidence, dan lift yang telah ditetapkan. Kolom antecedent merepresentasikan item atau kombinasi item yang menjadi pemicu rekomendasi, sedangkan consequent menunjukkan produk yang direkomendasikan sebagai akibat dari kemunculan antecedent dalam satu transaksi. Nilai support menggambarkan proporsi kemunculan aturan tersebut terhadap keseluruhan transaksi, sehingga mencerminkan tingkat frekuensi pola pembelian dalam dataset.

Nilai confidence menunjukkan tingkat kepercayaan bahwa kemunculan antecedent akan diikuti oleh consequent. Sebagai contoh, aturan “Molto Pink (820ml) → Molto Blue (820ml)” memiliki nilai confidence sebesar 0,962, yang mengindikasikan bahwa lebih dari 96% transaksi yang mengandung Molto Pink juga disertai dengan pembelian Molto Blue. Nilai confidence yang tinggi pada sebagian besar aturan dalam Tabel 3 menunjukkan adanya hubungan pembelian yang kuat dan konsisten antarproduk.

Sementara itu, nilai lift digunakan untuk mengukur kekuatan asosiasi dengan membandingkan kemunculan consequent pada kondisi antecedent terhadap kemunculannya secara acak. Seluruh aturan pada Tabel 3 memiliki nilai lift lebih besar dari 1, yang menandakan bahwa hubungan antarproduk bersifat positif dan tidak terjadi secara kebetulan. Semakin tinggi nilai lift, semakin kuat keterkaitan antarproduk tersebut, sehingga aturan dengan lift tinggi dianggap lebih bernilai dalam sistem rekomendasi.

Meskipun nilai confidence sebesar 0,8 secara umum dapat dikategorikan sebagai nilai yang relatif tinggi, pada penelitian ini hanya aturan dengan nilai confidence di atas ambang minimum yang ditetapkan dan memenuhi kriteria lift yang signifikan yang dipertahankan. Beberapa aturan dengan confidence di sekitar 0,8 tidak ditampilkan karena tidak memenuhi kombinasi kriteria seleksi secara simultan, khususnya pada aspek lift atau support, sehingga dianggap kurang optimal untuk diterapkan sebagai rekomendasi utama.

Dengan demikian, aturan asosiasi yang ditampilkan pada Tabel 3 merupakan aturan yang tidak hanya memiliki tingkat kepercayaan tinggi, tetapi juga didukung oleh frekuensi kemunculan yang memadai serta kekuatan hubungan yang signifikan. Hal ini memastikan bahwa rekomendasi produk yang dihasilkan lebih relevan, stabil, dan mencerminkan pola pembelian nyata pengguna dalam konteks e-commerce kebutuhan pokok.

3.2 Hasil Pembentukan Aturan Asosiasi (Association Rules)

Tahap berikutnya setelah pembentukan frequent itemset adalah menghasilkan aturan asosiasi berdasarkan tiga metrik utama, yaitu support, confidence, dan lift. Ketiga metrik ini digunakan untuk mengevaluasi kekuatan hubungan antarproduk sekaligus menentukan pola pembelian yang layak dijadikan dasar rekomendasi. Dari keseluruhan proses FP-Growth, lebih dari 100 aturan asosiasi berhasil dibentuk. Untuk kepentingan analisis pada jurnal ini, hanya ditampilkan aturan terbaik yang dikelompokkan ke dalam tiga kategori, yaitu Top 5 aturan berdasarkan nilai support tertinggi, Top 5 berdasarkan confidence tertinggi, dan Top 5 berdasarkan lift tertinggi. Ketiga tabel ini memberikan gambaran menyeluruh mengenai intensitas pembelian bersama, tingkat kepastian hubungan antarproduk, serta kekuatan asosiasi yang melampaui kebetulan statistik.

3.2.1 Aturan Asosiasi Berdasarkan Support

Aturan dengan nilai support tertinggi menggambarkan pasangan produk yang paling sering muncul secara bersamaan dalam transaksi pengguna. Nilai support yang besar menunjukkan bahwa kombinasi tersebut dibeli oleh sebagian besar pelanggan secara konsisten, sehingga mencerminkan pola konsumsi yang kuat pada tingkat populasi. Pada penelitian ini, aturan dengan support tertinggi terdapat pada kombinasi berikut, seperti yang ditampilkan pada Tabel 4.

Tabel 4. Aturan asosiasi dengan support tertinggi

No	Rule	Support
1	Indomie Goreng → Telur	0.228
2	Telur → Indomie Goreng	0.228
3	Sambal ABC → Telur	0.195
4	Telur → Sambal ABC	0.195
5	Indomie Goreng → Sambal ABC	0.192

Kombinasi pada Tabel 4. Memperlihatkan kecenderungan pelanggan membeli kebutuhan pokok dalam satu transaksi, terutama produk-produk yang secara umum digunakan bersama dalam kegiatan memasak atau kebutuhan harian rumah tangga.

3.2.2 Aturan Asosiasi Berdasarkan Confidence

Aturan dengan nilai confidence tinggi menggambarkan tingkat kepastian pembelian produk consequent ketika pelanggan membeli produk antecedent. Nilai confidence yang tinggi memperlihatkan hubungan yang stabil dan konsisten pada tingkat perilaku individu. Hasil analisis terbaru menunjukkan penguatan signifikan pada metrik ini, sebagaimana dirincikan pada Tabel 5. di mana beberapa aturan utama mencapai nilai maksimum.

Tabel 5. Aturan asosiasi dengan confidence tertinggi

No	Rule	Confidence
1	Sambal ABC, Indomie → Telur	1.000
2	Molto Pink, Molto Blue → Sunlight Jeruk Nipis	1.000
3	Molto Blue, Sunlight → Molto Pink	1.000
4	Sunlight, Molto Pink → Molto Blue	1.000
5	Minyak Goreng, Gula Pasir → Telur	1.000

Pada Tabel 5. Menunjukkan bahwa beberapa aturan asosiasi memiliki nilai confidence mencapai 1.0 (100%). Hal ini mengindikasikan adanya hubungan dependensi mutlak pada pola transaksi tertentu, di mana produk konsekuen (consequent) selalu dibeli bersamaan dengan produk antaseden (antecedent) dalam dataset pengujian. Tingginya

nilai ini merefleksikan karakteristik belanja rutin atau pembelian yang telah dimodelkan dalam skenario dataset.

3.2.3 Aturan Asosiasi Berdasarkan Lift

Nilai lift digunakan untuk menilai kekuatan keterkaitan antarproduk dengan membandingkan hubungan aktual terhadap peluang acak. Nilai lift lebih besar dari 1 menunjukkan bahwa pembelian suatu produk meningkatkan peluang pembelian produk lainnya secara signifikan. Pada penelitian ini, beberapa aturan menunjukkan nilai lift yang sangat tinggi. Seperti terlihat pada Tabel 6.

Tabel 6. Aturan asosiasi dengan lift tertinggi

No	Rule	Lift
1	Minyak Goreng (1l) → Minyak Goreng (550ml)	8.879
2	Minyak Goreng (550ml) → Minyak Goreng (1l)	8.879
3	Cocoa Powder (250g) → Susu Kental Manis	6.742
4	Molto Pewangi Pink, Sunlight → Molto Pewangi Blue	5.769
5	Molto Pewangi Pink, Molto Blue → Sunlight Jeruk Nipis	5.556

Pada Tabel 6. Nilai lift yang mencapai angka **8.879** mengindikasikan keterkaitan yang sangat kuat dan relevan untuk digunakan dalam sistem rekomendasi otomatis. Tingginya nilai ini pada kategori minyak goreng dan bahan kue (Cocoa + Susu) menegaskan bahwa kombinasi produk tersebut memiliki hubungan struktural yang kuat dalam pola konsumsi pengguna, di mana kehadiran satu produk secara drastis meningkatkan probabilitas pembelian produk pasangannya dibandingkan peluang acak.

3.3 Evaluasi Kinerja Rekomendasi

Berdasarkan pengujian terhadap data uji (testing set), diperoleh hasil evaluasi kinerja sistem sebagaimana ditunjukkan pada Tabel 7.

Tabel 7. Hasil Evaluasi Kinerja Sistem Rekomendasi

Metrik Evaluasi	Nilai (%)
Precision@4	29.17%
Recall@4	54.35%
F1-Score@4	37.96%
Hit Rate	54.35%

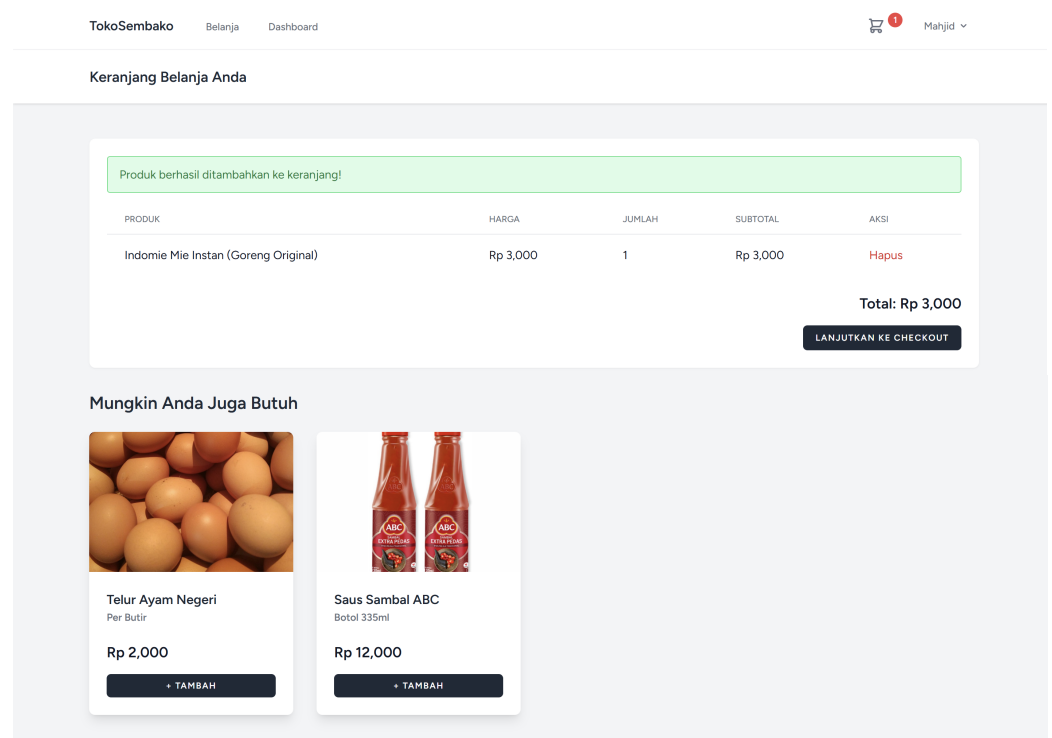
Hasil evaluasi pada Tabel 7. Menunjukkan nilai Hit Rate sebesar 54.35%, yang mengindikasikan bahwa pada lebih dari separuh kasus pengujian, sistem berhasil memberikan setidaknya satu rekomendasi produk yang akurat. Nilai Precision@4 sebesar 29.17% dinilai optimal mengingat batasan antarmuka Top-4, di mana mayoritas transaksi pengujian memiliki target item tunggal (1 item benar dari 4 slot = maksimal 25%). Tingginya nilai Hit Rate membuktikan bahwa algoritma FP-Growth efektif dalam mendeteksi dan menangkap pola asosiasi dominan yang telah dimodelkan ke dalam dataset berdasarkan skenario perilaku konsumen.

3.4 Implementasi Aturan Asosiasi dalam Sistem Rekomendasi

Aturan asosiasi yang dihasilkan dari algoritma FP-Growth kemudian diintegrasikan langsung ke dalam sistem e-commerce melalui modul rekomendasi yang telah dirancang khusus untuk memanfaatkan pola hubungan antarproduk. Integrasi ini memungkinkan sistem menampilkan daftar produk yang relevan pada halaman Product Detail maupun Checkout, dengan mengacu pada logika utama bahwa “jika pelanggan membeli atau

melihat produk X, maka sistem akan merekomendasikan produk Y yang memiliki nilai confidence atau lift tertinggi berdasarkan hasil FP-Growth.” Mekanisme tersebut bekerja secara real-time dengan memanfaatkan pemetaan antara frequent itemset dan aturan asosiasi yang terbentuk selama proses analisis.

Implementasi ini memberikan dampak langsung terhadap peningkatan personalisasi pengalaman pengguna, karena rekomendasi yang ditampilkan benar-benar didasarkan pada pola perilaku belanja aktual dan hubungan empiris antarproduk. Produk-produk yang muncul dalam rekomendasi merupakan item yang secara statistik memiliki kecenderungan tinggi dibeli bersamaan oleh pengguna lain dalam transaksi serupa, sehingga meningkatkan relevansi rekomendasi. Selain itu, sistem ini juga memungkinkan pengelola e-commerce untuk memahami pola permintaan produk secara lebih mendalam dan mengoptimalkan strategi pemasaran berbasis data. Implementasi hasil analisis aturan asosiasi ke dalam sistem rekomendasi ditampilkan dalam bentuk antarmuka pengguna, sebagaimana ditunjukkan pada Gambar 4.



Gambar 4. Tampilan rekomendasi produk pada e-commerce

Gambar 4 menunjukkan tampilan antarmuka sistem rekomendasi yang menampilkan daftar produk hasil rekomendasi berdasarkan aturan asosiasi FP-Growth. Produk direkomendasikan dalam format Top-4 recommendation yang disesuaikan dengan desain grid view pada antarmuka pengguna. Penyajian rekomendasi dalam jumlah terbatas bertujuan untuk meningkatkan fokus pengguna terhadap produk yang paling relevan, sekaligus mendukung hasil evaluasi sistem menggunakan metrik Precision@K, Recall@K, dan Hit Rate@K.

3.5 Pembahasan

Hasil penelitian ini menunjukkan bahwa algoritma FP-Growth mampu mengidentifikasi pola pembelian konsumen pada platform e-commerce kebutuhan pokok dengan tingkat akurasi dan efisiensi yang tinggi. Hal ini sejalan dengan penelitian yang dilakukan oleh Ridho [14] yang juga menemukan pola asosiasi yang signifikan pada data penjualan retail. Analisis frequent itemset serta aturan asosiasi memperlihatkan bahwa pola pembelian paling dominan muncul pada kelompok produk dapur seperti mie instan, telur ayam, dan tepung terigu yang merupakan kebutuhan konsumsi harian rumah tangga.

Selain itu, pola kuat juga terlihat pada kelompok produk kebersihan rumah tangga, terutama antara deterjen dan pewangi pakaian, serta pada beberapa kategori minuman dan produk susu. Keterkaitan antarproduk pada kategori ini terbentuk secara alami akibat kebutuhan penggunaan yang bersifat komplementer.

Pemilihan aturan asosiasi dengan nilai confidence yang relatif tinggi pada penelitian ini dilakukan secara sadar untuk menjaga kualitas rekomendasi yang dihasilkan. Meskipun nilai confidence sebesar 0,8 secara umum telah menunjukkan hubungan yang kuat antarproduk, pada konteks sistem rekomendasi e-commerce kebutuhan pokok, ambang confidence yang lebih tinggi diprioritaskan untuk mengurangi potensi rekomendasi yang kurang konsisten. Hal ini terutama penting mengingat dataset yang digunakan bersifat sintetis dan dirancang untuk merepresentasikan pola belanja rumah tangga secara realistis, sehingga stabilitas dan keandalan rekomendasi menjadi pertimbangan utama.

Aturan dengan nilai confidence di bawah ambang yang diprioritaskan cenderung menghasilkan rekomendasi yang lebih beragam namun kurang stabil pada tahap pengujian, khususnya ketika diterapkan pada skema Top-K recommendation. Oleh karena itu, penelitian ini menekankan penggunaan aturan dengan confidence tinggi yang juga didukung oleh nilai lift dan support yang signifikan, agar rekomendasi yang dihasilkan tidak hanya banyak secara kuantitas, tetapi juga relevan dan konsisten bagi pengguna. Pendekatan ini sejalan dengan tujuan sistem rekomendasi, yaitu memaksimalkan relevansi rekomendasi yang benar-benar bermanfaat bagi pengguna akhir.

Nilai lift yang tinggi pada sejumlah aturan memperkuat temuan bahwa terdapat strong associative behavior antara produk-produk tertentu. Hal ini menandakan bahwa hubungan antaritem bukan sekadar kebetulan statistik, melainkan mencerminkan kebiasaan belanja yang konsisten di antara pengguna. Penerapan aturan asosiasi ini ke dalam sistem rekomendasi memberikan dampak positif yang nyata bagi platform e-commerce, khususnya dalam meningkatkan peluang cross-selling, memperkaya personalisasi pengalaman belanja pengguna, dan berpotensi meningkatkan konversi penjualan secara keseluruhan [15].

Selain itu, integrasi FP-Growth ke dalam sistem backend dapat berjalan dengan baik berkat efisiensi algoritma dalam memproses dataset kecil hingga menengah. FP-Growth tidak memerlukan proses pembangkitan kandidat seperti pada algoritma Apriori, sehingga waktu komputasi menjadi jauh lebih cepat dan ringan. Dalam penelitian ini, seluruh proses analisis mulai dari pembentukan FP-Tree hingga generasi aturan asosiasi dapat dieksekusi hampir secara instan, memastikan bahwa sistem rekomendasi mampu diperbarui secara dinamis tanpa mengganggu performa platform e-commerce.

4. Kesimpulan

Penelitian ini berhasil mengimplementasikan algoritma FP-Growth sebagai dasar sistem rekomendasi produk pada platform e-commerce kebutuhan pokok. Berdasarkan pengolahan 600 transaksi pengguna, FP-Growth mampu mengidentifikasi frequent item-set dan aturan asosiasi yang merepresentasikan pola pembelian aktual, terutama pada produk dengan frekuensi konsumsi tinggi seperti mie instan, telur ayam, tepung terigu, deterjen, dan pewangi pakaian. Hasil evaluasi kuantitatif menunjukkan performa yang solid dengan Hit Rate mencapai 54.35%, membuktikan efektivitas sistem dalam menyajikan rekomendasi yang relevan.

Integrasi aturan asosiasi ke dalam backend Laravel melalui modul analisis Python memungkinkan sistem menghasilkan rekomendasi secara dinamis berdasarkan transaksi terbaru. Mekanisme ini meningkatkan relevansi rekomendasi, mendukung strategi cross-selling, dan memperkaya pengalaman belanja pengguna, sekaligus menunjukkan efisiensi FP-Growth dalam memproses dataset kecil hingga menengah tanpa membebani performa sistem.

Kontribusi utama penelitian ini terletak pada pembangunan alur kerja end-to-end, mulai dari eksekusi algoritma FP-Growth, penyimpanan aturan asosiasi ke basis data, hingga penampilan rekomendasi secara real-time. Pendekatan ini berbeda dari penelitian sebelumnya karena integrasinya langsung ke dalam sistem operasional e-commerce. Selain itu, penggunaan dataset simulatif yang menyerupai perilaku belanja nyata membuat hasil analisis lebih representatif terhadap konteks kebutuhan pokok.

Secara keseluruhan, FP-Growth terbukti efektif dan praktis untuk mendukung personalisasi serta pengambilan keputusan berbasis data pada sistem rekomendasi e-commerce. Pengembangan berikutnya dapat mencakup perluasan data transaksi riil dengan volume yang lebih besar, penerapan metode rekomendasi hibrida, dan penggabungan analisis prediktif untuk meningkatkan akurasi dan adaptabilitas sistem.

Daftar Pustaka

- [1] M. Hafizh, T. Novita, D. Guswandi, H. Syahputra, and L. Mayola, "Implementasi Data Mining Menggunakan Algoritma Fp-Growth Untuk Menganalisa Transaksi Penjualan Ekspor Online," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 5, no. 3, pp. 242–249, Jul. 2023, <https://doi.org/10.47233/jteksis.v5i3.847>.
- [2] J. Prayitno, B. Saputra, S. A. Rahayu, and T. Hariguna, "Market Basket Analysis Using FP-Growth Algorithm to Design Marketing Strategy by Determining Consumer Purchasing Patterns," *Journal of Applied Data Sciences*, vol. 4, no. 1, pp. 38–49, Jan. 2023, <https://doi.org/10.47738/jads.v4i1.83>
- [3] V. Dixit, D. Hebri, and M. Wagh, "Market Basket Analysis for Product Recommendation: Trends, Techniques, And Applications," *IJRTTE: International Journal of Recent Trends in Technology and Engineering*, vol. 4, no. 3, pp. 1–7, Jul. 2025, https://ijrtte.com/papers/VOL4-ISS3/Market_Basket_Analysis_for_Product_Recommendation_Trends_Techniques_And_Applications.pdf
- [4] T. A. Djabalul Lael and D. A. Pramudito, "Use of Data Mining for The Analysis of Consumer Purchase Patterns with The Fpgrowth Algorithm on Motor Spare Part Sales Transactions Data," *IAIC Transactions on Sustainable Digital Innovation (ITSDI)*, vol. 4, no. 2, pp. 128–136, Mar. 2023, <https://doi.org/10.34306/itsdi.v4i2.582>.
- [5] Y. R. Adam Nugraha, A. A. Maftahuhillah, A. Nur Rachman, E. N. Fitriani, and G. N. Tarempa, "Implementation of Apriori Algorithm to Analyze Sales Transaction Patterns in Official E-Commerce," *JESII: Journal of Elektronik Sistem InformasI*, vol. 3, no. 1, pp. 62–70, Sep. 2025, <https://doi.org/10.31848/jesii.v3i1.4127>.
- [6] S. Aulia, A. N. Muhammad, and A. Wibowo, "Optimization of Customer Segmentation with RFM, K-Means, and FP-Growth for Marketing Strategy," *SINTECH Journal*, vol. 8, no. 2, pp. 163–177, Aug. 2025, <https://ejournal.institi.ac.id/index.php/sintechjournal/article/view/1942>
- [7] A. Fairuzindah, I. R. A. Islami, N. Rexa, S. Anggraini, and E. Sunandi, "Implementasi Market Basket Analysis Dengan Algoritma Frequent Pattern Growth Pada Data Transaksional di Electronic Commerce," *JDMIS: Journal of Data Mining and Information Systems*, vol. 3, no. 2, pp. 101–107, Aug. 2025, <https://doi.org/10.54259/jdmis.v3i2.4593>.
- [8] B. Foster and M. D. Johansyah, "Batik Sales Product Recommendation System On E-Commerce Website Using FP-Growth Algorithm," *Año*, vol. 36, pp. 197–212, Feb. 2020. <https://produccioncientificaluz.org/index.php/opcion/article/view/31844/33093>
- [9] T. R. Siam, M. A. Mozumder, S. A. Sakib, M. S. Arefin, and A. W. Reza, "Mining Association Rules for Optimizing Customer Purchase Behavior in E-Commerce Transactions," in *2025 International Conference on Quantum Photonics, Artificial Intelligence, and Networking (QPAIN)*, IEEE, Jul. 2025, pp. 1–6. <https://doi.org/10.1109/QPAIN66474.2025.11172084>.
- [10] A. A. Shihab and Z. Fatah, "Implementasi Algoritma FP-Growth Pada Dataset Sintetis Untuk Penentuan Pola Pembelian Sembako Dan Kebutuhan Harian," *Jurnal Ilmiah Multidisiplin Nusantara (JIMNU)*, vol. 2, no. 3, pp. 161–175, Nov. 2023, <https://doi.org/10.59435/jimnu.v2i3.452>.
- [11] M. Nur Faizi, I. Yulia, M. Afridon, A. Arizka, J. Nathaniel Sulisty, and P. Negeri Bengkalis, "Perbandingan Performa Framework Laravel, Flask API Python, dan PHP Native untuk Aplikasi API pada Data AIS Polbeng," *Seminar Nasional Industri dan Teknologi (SNIT)*, pp. 17–20, Dec. 2024, <https://intechbiz.polbeng.ac.id/eprosiding/index.php/snit/article/view/659>
- [12] Di. P. Mulya, "Analisa dan Implementasi Assosiation Rule Dengan Algoritma FP-Growth Dalam Seleksi Pembelian Tanah Liat (Studi Kasus di PT. Anveve Ismi Berjaya)," *Jurnal Teknologi Dan Sistem Informasi Bisnis*, vol. 1, no. 1, pp. 47–57, Jan. 2019, <https://doi.org/10.47233/jteksis.v1i1.6>.
- [13] A. Hany Talia, N. Suarna, and D. Pratama, "Penerapan Algoritma FP-Growth Dalam Analisis Pola Transaksi Untuk Optimalisasi Pengelolaan Data Transaksi di Toko Lia," *Jurnal Kecerdasan Buatan dan Teknologi Informasi*, vol. 3, no. 1, pp. 26–36, 2024, <https://ojs.ninetyjournal.com/index.php/JKBTI/article/view/108>

-
- [14] A. N. Ridho, A. P. A. Masa, and P. P. Widagdo, "Implementasi Market Basket Analysis Pada Data Penjualan CV. Xyz Menggunakan Algoritma FP-Growth," *Jurnal Informatika dan Teknik Elektro Terapan*, vol. 12, no. 3, Aug. 2024, <https://doi.org/10.23960/jitet.v12i3.4541>.
 - [15] F. Z. Ghassani, Asep Jamaludin, and Agung Susilo Yuda Irawan, "Market Basket Analysis Using the FP-Growth Algorithm to Determine Cross-Selling," *Jurnal Informatika Polinema*, vol. 7, no. 4, pp. 49–54, Aug. 2022, <https://doi.org/10.33795/jip.v7i4.508>.