

Simulasi Algoritma Apriori dan FP-Growth Dalam Menentukan Rekomendasi Kodefikasi Barang Pada Transaksi Persediaan**Purwita Sari^{1*}, Lucky Indra Kesuma², Ahmad Fali Oklilas³, M. Ali Buchari⁴**wita@ilkom.unsri.ac.id, luckyindra25@gmail.com, faliunsri@gmail.co], m.ali.buchari@gmail.com
Universitas Sriwijaya

Informasi Artikel	Abstrak
Diterima : 23 Dec 2023 Direview : 4 Jan 2024 Disetujui : 10 Feb 2024	Keberhasilan proses pembangunan memerlukan dukungan optimal dalam pertukaran data dan informasi antar instansi guna mencapai integrasi sistem yang seimbang antara pemerintah dan para pengguna. SAKTI, sebuah aplikasi keuangan tingkat instansi, telah dirancang untuk mengelola segala aspek keuangan, mulai dari perencanaan hingga pertanggungjawaban anggaran. Aplikasi SAKTI ini mengintegrasikan semua aplikasi satuan kerja yang ada, bertujuan untuk meningkatkan efektivitas, efisiensi, transparansi, dan akuntabilitas dalam pengelolaan keuangan. Meskipun telah diimplementasikan sejak awal tahun 2022, operator komitmen masih menghadapi kendala dalam penentuan kodefikasi barang, terutama karena kurangnya familiaritas dengan tugas tersebut dan jumlah barang yang banyak sebagai referensi. Kesalahan yang dilakukan oleh operator komitmen dapat berdampak pada proses pendetailan aset pada modul persediaan dan aset. Dalam penelitian ini, peneliti menggunakan metode Algoritma Apriori dan frequent pattern growth (FP-growth) sebagai alat untuk menemukan sejumlah aturan asosiasi dari data transaksi barang yang disimpan dalam basis data aplikasi SAKTI. Hasil simulasi menunjukkan bahwa aturan yang memenuhi minimum support dan minimum confidence, dengan pemilihan terbanyak adalah Ballpoint Standar Tecno, refill tisu plastik, Lak Ban Hitam 2 Inchi Merk Daimaru, dan Ballpoint Kenko K1 (0,5) sebesar 100%.
Keywords	Abstrak
Apriori, FP-Growth, Item Code	<i>The success of the development process requires optimal support in exchanging data and information between agencies in order to achieve balanced system integration between the government and users. SAKTI, an agency-level financial application, has been designed to manage all financial aspects, from planning to budget accountability. This SAKTI application integrates all existing work unit applications, aiming to increase effectiveness, efficiency, transparency and accountability in financial management. Even though it has been implemented since the beginning of 2022, commitment operators still face obstacles in determining item codification, mainly due to a lack of familiarity with the task and the large number of items as references. Errors made by commitment operators can have an impact on the asset detailing process in the inventory and asset modules. In this research, researchers used the Apriori algorithm method and frequent pattern growth (FP-growth) as a tool to find a number of association rules from goods transaction data stored in the SAKTI application database. The simulation results show that the rules that meet the minimum support and minimum confidence, with the most votes being Tecno Standard Ballpoints, plastic tissue refills, Daimaru Brand 2 Inch Black Tire Lacquer, and Kenko K1 Ballpoints (0.5) at 100%.</i>

A. Pendahuluan

Dalam lingkungan pemerintah, perubahan dalam konteks strategis dan kemajuan teknologi mendorong aparatur pemerintah untuk mengantisipasi paradigma baru. Upaya peningkatan kinerja birokrasi dan perbaikan pelayanan diarahkan menuju tercapainya pemerintahan yang baik (*good governance*). Poin penting yang perlu diperhatikan adalah bahwa sektor pemerintah bukan hanya menjadi penggerak, tetapi juga fasilitator utama dalam menjamin keberhasilan berbagai kegiatan pembangunan. Oleh karena itu, penting bagi keberhasilan pembangunan untuk didukung oleh efisiensi dalam pertukaran data dan informasi antar instansi, guna menciptakan keterpaduan sistem antara pemerintah dan pihak pengguna lainnya [1].

SAKTI (Sistem Aplikasi Keuangan Tingkat Instansi) dimulai pada akhir tahun 2021, tetapi pelaksanaannya telah diatur oleh Peraturan Menteri Keuangan Nomor 223/PMK.05/2015 pada tanggal 15 Desember 2015, yang mengatur pelaksanaan uji coba SAKTI dan telah mengalami perubahan melalui Peraturan Menteri Keuangan Nomor 203/PMK.05/2019 pada tanggal 27 Desember 2019 [2]. Selanjutnya, seluruh satuan kerja (satker) akan melaksanakan implementasi penuh dari SAKTI, termasuk Kelompok Modul Pelaksanaan dan Kelompok Modul Pelaporan. SAKTI, sebagai aplikasi keuangan tingkat instansi, berfungsi sebagai sarana bagi satker untuk mendukung implementasi Sistem Perbendaharaan Anggaran Negara (SPAN). Aplikasi ini bertanggung jawab atas pengelolaan keuangan yang mencakup tahap perencanaan hingga pertanggungjawaban anggaran, serta mengintegrasikan seluruh aplikasi yang dimiliki oleh satker [3][4][5].

Dengan penerapan aplikasi SAKTI ini, diharapkan manajemen keuangan dapat menjadi lebih efektif dan efisien, mendukung pencapaian pengelolaan keuangan negara yang profesional, transparan, dan akuntabel [6]. Pelaksanaan aplikasi SAKTI dimulai sejak awal tahun 2022. Namun, dalam menjalankan tugasnya, operator komitmen masih sering menghadapi hambatan terkait penentuan kodefikasi barang. Hal ini disebabkan oleh kurangnya familiaritas dengan tugas tersebut dan jumlah barang yang banyak menjadi referensi. Kesalahan yang dilakukan oleh operator komitmen dapat berdampak pada proses rincian aset dalam modul persediaan dan aset. Oleh karena itu, dalam penelitian ini, akan dicari solusi atau menggunakan algoritma untuk menentukan kodefikasi barang yang tepat. Kriteria kecocokan di sini merujuk pada kebenaran kode barang, yaitu barang yang memang aktif digunakan dalam satker dan sesuai dengan kelompoknya.

Berdasarkan beberapa tinjauan dan permasalahan yang telah diidentifikasi sebelumnya, penelitian ini bertujuan untuk mengembangkan sebuah simulasi yang mengimplementasikan algoritma Apriori dan FP-Growth. Simulasi ini dirancang untuk memberikan kemudahan dalam meramalkan atau memberikan pilihan selama proses penentuan kodefikasi barang. Keuntungan dari penelitian ini melibatkan kemudahan dalam menentukan kodefikasi barang dan peningkatan efektivitas dalam penyusunan laporan bagi instansi yang menggunakan aplikasi SAKTI. Hasilnya diharapkan dapat mengurangi kesalahan dalam menetapkan kodefikasi barang secara signifikan.

Dalam penelitian sebelumnya, pemanfaatan algoritma Apriori dengan metode FP-Growth telah terbukti memberikan dukungan kepada pihak manajemen dalam menentukan letak barang yang umumnya dibeli oleh konsumen. Hal ini bertujuan

untuk mempermudah pelanggan dalam membeli barang-bagian tersebut, sementara juga membantu pihak manajemen dalam melakukan pemantauan terhadap stok barang. [7].

Dalam kerangka penelitian ini, peneliti menerapkan metode Algoritma Apriori dan frequent pattern growth (FP-growth), yang merupakan dua algoritma yang sangat terkenal, untuk mengidentifikasi sejumlah frequent itemset dari data transaksi yang disimpan dalam basis data [8][9][10]. Dalam konteks penelitian ini, kedua algoritma tersebut digunakan sebagai alat untuk menemukan sejumlah aturan asosiasi dari data transaksi barang yang tercatat dalam aplikasi SAKTI. Tujuannya adalah untuk mengusulkan integrasi algoritma ini sebagai bagian integral dari aplikasi SAKTI, dengan harapan dapat mengurangi kesalahan pada tahap penentuan kodefikasi barang. Implementasi ini diharapkan dapat meningkatkan akurasi dan akuntabilitas laporan persediaan.

B. Metode Penelitian

Pendekatan penelitian yang diterapkan dalam penelitian ini adalah pendekatan kualitatif. Metode kualitatif, dikenal sebagai metode yang relatif baru, termasuk dalam kategori postpositivisme. Metode penelitian kualitatif, yang mendasarkan diri pada filsafat postpositivisme, digunakan untuk menyelidiki obyek yang bersifat alamiah (sebagai contoh, eksperimen awalnya) di mana peneliti berperan sebagai instrumen utama. Pengumpulan data dilakukan melalui teknik triangulasi, yang merupakan gabungan dari berbagai pendekatan, sedangkan analisis cenderung bersifat induktif dan kualitatif. Hasil dari penelitian kualitatif lebih menitikberatkan pada pemahaman mendalam daripada pada generalisasi [11].

Penelitian ini mengadopsi pendekatan kualitatif untuk menganalisis pola permintaan barang di lingkungan Universitas Sriwijaya menggunakan metode perhitungan algoritma Apriori dan FP-Growth. Tahapan penelitian yang dilakukan oleh peneliti tergambar pada gambar di bawah ini:



Gambar 1. Tahapan Penelitian

Dalam tahap literatur review, peneliti memberikan penjelasan teoritis dan konsep terkait variabel serta subvariabel yang relevan dengan topik penelitian. Data ini digunakan sebagai pendukung dalam penyelesaian masalah pada penelitian.

Algoritma Apriori merupakan algoritma dasar yang digunakan untuk menentukan Frequent itemsets pada aturan asosiasi Boolean [12]. Algoritma ini termasuk dalam jenis Aturan Asosiasi dalam bidang data mining. Aturan yang mencerminkan asosiasi antara beberapa atribut sering disebut affinity analysis atau market basket analysis. Analisis asosiasi, atau association rule mining, adalah teknik data mining yang digunakan untuk menemukan aturan kombinasi item [13]. Salah satu tahap analisis asosiasi yang menarik perhatian banyak peneliti adalah analisis pola frekuensi tinggi (frequent pattern mining). Dua tolok ukur penting untuk mengetahui signifikansi suatu asosiasi adalah support dan confidence. Support (nilai penunjang) adalah persentase kombinasi item dalam database, sementara confidence (nilai kepastian) mengukur kekuatan hubungan antara item dalam aturan asosiasi [14]. Algoritma Apriori dibagi menjadi beberapa tahap yang disebut pass [15][16][17].

1. Pembentukan Calon Itemset

Calon k-itemset dibuat melalui kombinasi (k-1)-itemset yang diperoleh dari iterasi sebelumnya. Salah satu metode dalam algoritma Apriori adalah melakukan pemangkasan terhadap calon k-itemset yang memiliki subset yang tidak termasuk dalam pola frekuensi tinggi dengan panjang k-1.

2. Perhitungan dukungan untuk setiap calon k-itemset


Dukungan untuk setiap calon k-itemset dihitung dengan melakukan pemindaian pada database untuk menghitung jumlah transaksi yang memuat semua item dalam calon k-itemset tersebut. Ini juga merupakan karakteristik dari algoritma Apriori, di mana diperlukan perhitungan dengan memeriksa seluruh database untuk setiap k-itemset terpanjang.

3. Penetapan pola frekuensi tinggi

Pola frekuensi tinggi yang mencakup k item atau k-itemset ditetapkan dari calon k-itemset yang memiliki dukungan lebih tinggi dari nilai minimum yang ditetapkan.

4. Jika tidak ada pola frekuensi tinggi baru yang ditemukan, maka seluruh proses dihentikan.

Untuk memahami proses algoritma Apriori dengan lebih baik, berikut akan disajikan ilustrasi penggunaan algoritma ini. Dengan menggunakan database pada gambar 2 dan mengasumsikan bahwa jumlah transaksi minimum yang diperlukan adalah 2.



Gambar 2. Ilustrasi Algoritma Apriori

Ada beberapa metode yang dapat digunakan untuk menerapkan association rule mining, dan salah satu di antaranya adalah algoritma FP-Growth atau Frequent Pattern Growth [18]. Algoritma ini merupakan suatu perbaikan dari algoritma Apriori, dimana kelebihanannya terletak pada efisiensi dan penghematan biaya yang lebih tinggi karena dapat mengurangi waktu dan ruang penyimpanan yang diperlukan [19]. Algoritma FP-Growth tidak memerlukan pembentukan target kandidat untuk mengambil kombinasi produk dari database, suatu perbedaan signifikan dengan algoritma Apriori [20]. Pendekatan pembentukan kandidat pada algoritma FP-Growth memastikan bahwa kelompok kandidat berada di antara elemen-elemen yang serupa.

Sementara itu, algoritma FP-Growth mengidentifikasi item yang sering muncul dengan menerapkan konsep pengembangan FP-Tree. Algoritma FP-Growth fokus pada pencarian item yang memiliki kemunculan paling tinggi dalam data yang sedang diselidiki. Dalam kerangka penelitian ini, dilakukan prosedur penentuan target secara berulang yang terdiri dari dua langkah [21]:

a) Pembentukan FP-Tree

FP-Tree adalah representasi data yang terekspresikan secara terkompresi. Struktur data FP-Tree dibangun dengan mencatat data transaksi pada setiap jalur FP-Tree. Hal ini karena setiap transaksi dapat berisi beberapa objek, memungkinkan terjadinya kompresi jalur yang efisien dalam struktur data FP-Tree.

b) Implementasi Algoritma FP-Growth

a. Generasi Conditional Pattern Base

Conditional pattern base mengacu pada subdatabase yang memiliki template awalan dan akhiran untuk suatu pola. FP-Tree digunakan sebagai dasar pembentukan model.

b. Generasi Conditional FP-Tree

Apabila jumlah support minimum lebih kecil daripada jumlah support, seluruh item akan dihasilkan dengan FP-Tree.

c. Pencarian Frequent Itemset

Seluruh set item akan diturunkan dengan menggabungkan item pada setiap Conditional FP-Tree. Langkah ini dilakukan jika hanya terdapat satu jalur

pada Conditional FP-Tree.

Langkah berikutnya melibatkan pengumpulan data primer dan sekunder. Untuk data primer, peneliti mengumpulkan informasi secara langsung menggunakan metode wawancara dan observasi di lingkungan Universitas Sriwijaya.

1. Wawancara: Metode ini digunakan untuk menggali informasi terkait pola penggunaan Sistem Aplikasi Tingkat Instansi yang telah diimplementasikan di Universitas Sriwijaya. Data yang digunakan dalam perhitungan data mining melibatkan informasi pengeluaran barang persediaan pada tahun 2022 dan data referensi barang persediaan yang tercatat dalam Aplikasi SIANIS.
2. Observasi: Dengan mengamati secara langsung kejadian yang terjadi pada sistem aplikasi Tingkat Instansi dan penggunaan aplikasi SIANIS.

Guna mendapatkan data sekunder, peneliti menghimpun data terkait dengan penelitian, khususnya data pengeluaran barang. Data sekunder yang dikumpulkan mencakup informasi peminjaman buku, berbagai dokumen baik dalam bentuk tertulis maupun dalam bentuk softcopy, gambar, foto, serta dokumen elektronik lainnya yang dapat memberikan dukungan pada tahap penulisan.

Penelitian ini melakukan pengolahan data dengan merujuk pada proses Knowledge Discovery in Database (KDD). Berikut adalah tahapan-tahapan dalam proses KDD:

a) Selection

Data yang diperoleh melalui tahap pemilihan awal. Data yang diambil adalah rekaman transaksi pengeluaran barang selama satu tahun, mulai dari tanggal 1 Januari hingga 31 Desember 2022, yang mencakup 6.316 catatan transaksi dengan 1.214 ID transaksi. Melalui seleksi data ini, diharapkan proses pengolahan dapat dilakukan dengan lebih baik sesuai dengan tujuan penelitian yang ingin dicapai.

b) Pre-processing

Pre-processing data adalah serangkaian langkah persiapan data sebelum memulai proses data mining. Berikut adalah beberapa langkah pre-processing data yang diterapkan dalam penelitian ini:

- 1) Pembersihan Data (Data Cleaning): Menghilangkan data transaksi yang tidak lengkap dan tidak mengandung informasi penting seperti nama barang, tanggal, dan kode barang.
- 2) Reduksi Data (Data Reduction): Mengurangi variabel yang tidak relevan pada data transaksi yang diperoleh dari perusahaan.
- 3) Integrasi Data (Data Integration): Menggabungkan produk dengan jenis yang sama untuk membentuk kelompok produk yang lebih terpadu.

c) Transformasi Data: Transformasi data diperlukan sebelum melakukan pengolahan menggunakan teknik data mining. Data transaksi konsumen diubah menjadi format data per transaksi, dengan setiap transaksi direpresentasikan dalam baris tersendiri. Hal ini memungkinkan data dapat diolah lebih lanjut menggunakan perangkat lunak RapidMiner.

d) Data Mining

Proses pengolahan data berdasarkan algoritma yang sesuai dengan teknik data mining menggunakan perangkat lunak RapidMiner. Algoritma yang diterapkan

dalam penelitian ini adalah algoritma FP-Growth, yang termasuk salah satu algoritma dalam metode association rule mining. Oleh karena itu, hasil dari teknik ini berupa asosiasi yang terbentuk dari data yang telah diolah.

e) Interpretation Evaluation

Merupakan tahapan di mana hasil asosiasi yang diperoleh dari teknik data mining diinterpretasikan. Selanjutnya, proses evaluasi dilakukan berdasarkan parameter algoritma yang digunakan, seperti support, confidence, dan lift. Dengan demikian, informasi baru dapat diperoleh berdasarkan hasil analisis yang telah dilakukan.

Dalam penelitian ini, peneliti memanfaatkan dua algoritma untuk memudahkan operator dalam menentukan kodefikasi barang persediaan, dengan tujuan mengurangi tingkat kesalahan dalam penyajian laporan. Pertama, Algoritma Apriori digunakan sebagai alat untuk mencari frequent itemset melalui Teknik association rule [22]. Algoritma Apriori terdiri dari dua tahap utama, yaitu join dan prune, dengan penerapan nilai minimum support dan minimum confidence [23]. Nilai support mencerminkan persentase kemunculan suatu transaksi dalam dataset, sementara confidence mengindikasikan persentase kemunculan Y pada transaksi yang mengandung X. Rumus nilai support dijelaskan dalam (1), dan nilai confidence dijelaskan dalam (2).

$$support(X) = \frac{\sum transaksiX}{\sum transaksi} \quad (1) \quad confidence(X|Y) = \frac{supportX|Y}{occurrenceX} \quad (2)$$

Dalam makalah [24], algoritma Apriori digunakan untuk menentukan materi yang sesuai dengan kebutuhan mahasiswa di Open University Cina. Penentuan materi ini didasarkan pada pilihan jurusan yang tersedia, dan algoritma Apriori menghasilkan dua kelompok aturan kuat yang dapat dijadikan rekomendasi. Berikut adalah contoh pencarian aturan dengan menggunakan nilai minimum support dan minimum confidence pada transaksi:

Tabel 1. Tabel Traansaksi

Transaksi ID	Item set
1	A,B,C
2	A,C
3	A,D
4	B,E,F

Nilai yang digunakan dalam proses ini adalah minimum support sebesar 0.5 dan minimum confidence sebesar 0.5. Pada tahap awal, dilakukan pencarian nilai support untuk setiap item, di mana item yang memiliki nilai support kurang dari minimum support akan mengalami pemangkasan. Sedangkan untuk item yang memiliki nilai support di atas minimum support, dilakukan proses join. Pada langkah ini, C (Candidate) menunjukkan item kandidat, sementara L (Large) menunjukkan Large itemset.

C1 =

Items	Support
A	3
B	2
C	2
D	1
E	1
F	1

L1 =

Items	Support
A	3
B	2
C	2

C2 =

Items	Support
{A,B}	3
{A,C}	2
{B,C}	2

L2 =

Items	Support
{A,C}	2

Setelah tidak ada lagi proses penggabungan yang dapat dilakukan pada Large itemset, langkah berikutnya melibatkan perhitungan nilai confidence.

Tabel 2. Hasil Association

Association rule	Support	Support %	Confidence	Confidence %
$A \rightarrow C$	2/4	50%	2/3	66%
$C \rightarrow A$	2/4	50%	2/2	100%

Berikutnya, Algoritma FP-Growth menyajikan salah satu alternatif algoritma yang sangat efisien dalam pencarian frequent itemset dalam kumpulan data yang besar [25]. FP-Growth mampu mengidentifikasi frekuensi itemset dengan mengakses database asli hanya dalam jumlah yang minimal, menjadikannya pendekatan yang sangat efisien. Selain itu, FP-Growth mampu mengatasi masalah yang mungkin timbul jika jumlah calon itemsets terlalu besar. FP-Growth menggunakan struktur awal yang disebut Tree (FP-Tree) untuk mengatur dan mengelola data [26].

C. Hasil dan Pembahasan

Data pengeluaran barang persediaan di Universitas Sriwijaya selama satu tahun telah dikumpulkan, diseleksi, dan hasilnya diperoleh dalam bentuk tabel sebagai berikut:

Tabel 3. Tabel Sample Barang Persediaan

No	Kode Barang	Nama Barang	Alias
1	0000000000000004	reffil tissu plastik	A
2	1010302000000001	Kertas A4 70 Gram Bola Dunia	B
3	1010302001000043	Kertas A4 80 gramBola Dunia	C
4	1010301001000109	Lak Ban Hitam 2 Inchi Merk Daimaru	D
5	1010301001000050	Ballpoint Kenko K1 (0,5)	E
6	1010305999000328	Tissue paseo	F
7	1010305012000091	Pengharum Mobil Glade	G
8	1020103999000065	Isi Necis NO.10 Merk Kangaro	H
9	1010306010000019	Battery ABC Alkaline AA	I
10	0000000423000001	SUNLIGHT THL	J
11	1010302001000015	Kertas HVS Folio 70 Gram Merk Bola Dunia	K
12	1010304006000027	Flasdis SanDisk 8 GB	L
13	1010305008000053	Karbol Pewangi Toilet Wipol kemasan Plastik	M
14	1010301001000018	Ballpoint Standard Tecno	N
15	1010301001000021	Ballpoint Balliner Biru	O
16	1010301001000138	Pengharum Ruangan Spray Merk Glade	P
17	1010301001000228	Sunlight Pembersih (Sunlight)	Q
18	1010305012000020	Air Freshener Stella Plastik	R
19	1010306010000029	Battery AAA ABC Alkaline	S

Dalam tabel ini, terdapat informasi mengenai daftar barang yang akan dijadikan sampel dalam proses simulasi algoritma Apriori dan FP-Growth.

Tabel 4. Sample Transaksi Pengeluaran Barang

Trx	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	3			2					2	1	5		1	6		1		1	2
2	2	10	5	5	5		1	2						12		1	4		
3	2				5			5		2				6	10	1			
4	2			10							3		3	12				1	4
5	5													3		1			2
6	1			2				3			5		2	6		1			
7			10	2	12					1				12		1			
8	3	5		3				4						12					
9	2	2	5		6		1		4	3				12	5	1			2
10	5	5	2	5	4									6	5	1	2	1	
11			2	10	12					1	4			6					
12		10	5		12					2				12	6				
13							1		4			1							4
14					6	10		3						12	6				
15	2	3	10		6											1	2		
16			5	2						1			1						
17			5			4		6						12	4				


18	2		5		1		4		6		1	2
19	2	5	5	12					6	12	2	
20	3	10	5	12		6				12		

Tabel 4 berisi data transaksi pengeluaran barang selama satu tahun, mulai dari tanggal 1 Januari hingga 31 Desember 2022, dengan total 6.316 catatan transaksi. Data ini telah diurutkan berdasarkan 19 item barang yang paling sering dikeluarkan, dan dipilih sebanyak 20 transaksi. Tabel ini mencakup 1.214 ID transaksi.

Tabel 5. Konversi Binominal Transaksi Pengeluaran Barang


Trx	A	B	C	D	E	F	G	H	I	J	K	L	M	N	O	P	Q	R	S
1	1	0	0	1	0	0	0	0	1	1	1	0	1	1	0	1	0	1	1
2	1	1	1	1	1	0	1	1	0	0	0	0	0	1	0	1	1	0	0
3	1	0	0	0	1	0	0	1	0	1	0	0	0	1	1	1	0	0	0
4	1	0	0	1	0	0	0	0	0	0	1	0	1	1	0	0	0	1	1
5	1	0	0	0	0	0	0	0	0	0	0	0	0	1	0	1	0	0	1
6	1	0	0	1	0	0	0	1	0	0	1	0	1	1	0	1	0	0	0
7	0	0	1	1	1	0	0	0	0	1	0	0	0	1	0	1	0	0	0
8	1	1	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0
9	1	1	1	0	1	0	1	0	1	1	0	0	0	1	1	1	0	0	1
10	1	1	1	1	1	0	0	0	0	0	0	0	0	1	1	1	1	1	0
11	0	0	1	1	1	0	0	0	0	1	1	0	0	1	0	0	0	0	0
12	0	1	1	0	1	0	0	0	0	1	0	0	0	1	1	0	0	0	0
13	0	0	0	0	0	0	1	0	1	0	0	1	0	0	0	0	0	0	1
14	0	0	0	0	1	1	0	1	0	0	0	0	0	1	1	0	0	0	0
15	1	1	1	0	1	0	0	0	0	0	0	0	0	0	0	1	1	0	0
16	0	0	1	1	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0
17	0	0	1	0	0	1	0	1	0	0	0	0	0	1	1	0	0	0	0
18	1	0	0	1	0	0	1	0	0	0	1	0	0	1	0	0	0	1	1
19	1	1	0	1	1	0	0	0	0	0	0	0	0	1	1	0	1	0	0
20	1	1	0	1	1	0	0	1	0	0	0	0	0	0	1	0	0	0	0
Tot	13	8	9	12	11	2	4	7	3	7	5	1	4	16	8	9	4	4	6

Tabel 5 memuat hasil konversi binominal transaksi pengeluaran barang, di mana data awalnya bersifat numerik, tetapi perlu dikonversi menjadi data nominal untuk pengolahan menggunakan algoritma Apriori.



Gambar 3. Simulasi Algoritma Apriori dan FP Growth Transaksi Pengeluaran

Pada Gambar 3, terlihat desain hasil implementasi algoritma Apriori dan FP-Growth menggunakan perangkat lunak RapidMiner 7. Langkah-langkah yang dilakukan pada gambar tersebut melibatkan membaca data transaksi pengeluaran dari file Excel. Selanjutnya, dilakukan penghitungan frekuensi menggunakan operator "decretize frequency," kemudian dilanjutkan dengan konversi dari bilangan numerik ke nominal menggunakan operator "binominal conversion." Setelah itu, dilakukan pemanggilan operator FP-Growth dan Apriori untuk melanjutkan proses analisis.



Gambar 4. Grafis Rule sampel data pengeluaran Barang menggunakan RapidMiner

Dalam Gambar 4 di atas, terlihat bahwa hasil perhitungan menggunakan Algoritma Apriori dan FP-Growth dapat menghasilkan aturan asosiasi dengan nilai support di atas 50% dan confident 90%, menghasilkan sebanyak 85 aturan asosiasi dengan nilai confident 100%.

Tabel 6. Frekuensi Item Set (FP-Growth)

No	Kode Barang	Nama Barang	Alias	Support
1	0000000000000004	refill tissu plastik	A	63%
4	1010301001000109	Lak Ban Hitam 2 Inchi Merk Daimaru	D	58%
5	1010301001000050	Ballpoint Kenko K1 (0,5)	E	58%
14	1010301001000018	Ballpoint Standard Tecno	N	78%

Tabel 7. Hasil Asosiasi Rule Transaksi Pengeluaran

No	Premises	Conclusion	Support	Confidence
1	K	N	21%	100%
2	Q	A	21%	100%
3	Q	E	21%	100%
4	K	D	21%	100%
5	Q	B	21%	100%
6	N, S	A	21%	100%
7	A, S	N	21%	100%
8	N, J	E	26%	100%
9	E, J	N	26%	100%
10	D, P	N	21%	100%
11	K	N, D	21%	100%
12	N, K	D	21%	100%
13	D, K	N	21%	100%
14	C, O	N	21%	100%
15	A, C	E	21%	100%
16	A, O	E	26%	100%
17	Q	A, E	21%	100%
18	A, Q	E	21%	100%
19	E, Q	A	21%	100%
20	D, B	A	26%	100%
21	D, H	A	21%	100%
22	A, C	P	21%	100%
23	A, C	B	21%	100%
24	P, B	A	21%	100%
25	Q	A, B	21%	100%
26	A, Q	B	21%	100%
27	B, Q	A	21%	100%
28	C, P	E	26%	100%
29	C, B	E	26%	100%

30	P, B	E	21%	100%
31	O, B	E	26%	100%
32	Q	E, B	21%	100%
33	E, Q	B	21%	100%
34	B, Q	E	21%	100%
35	P, B	C	21%	100%
36	N, A, O	E	21%	100%
37	N, D, B	A	21%	100%
38	N, D, C	E	21%	100%
39	E, D, C	N	21%	100%
40	N, C, P	E	21%	100%
41	N, C, B	E	21%	100%
42	N, C, J	E	21%	100%
43	E, C, J	N	21%	100%
44	N, O, B	E	21%	100%
45	A, E, D	B	21%	100%
46	E, D, B	A	21%	100%
47	A, C	E, P	21%	100%
48	A, E, C	P	21%	100%
49	A, C, P	E	21%	100%
50	A, C	E, B	21%	100%
51	A, E, C	B	21%	100%
52	A, C, B	E	21%	100%
53	P, B	A, E	21%	100%
54	A, P, B	E	21%	100%
55	E, P, B	A	21%	100%
56	A, O, B	E	21%	100%
57	Q	A, E, B	21%	100%
58	A, Q	E, B	21%	100%
59	E, Q	A, B	21%	100%
60	A, E, Q	B	21%	100%
61	B, Q	A, E	21%	100%
62	A, B, Q	E	21%	100%
63	E, B, Q	A	21%	100%
64	A, C	P, B	21%	100%
65	A, C, P	B	21%	100%
66	A, C, B	P	21%	100%
67	P, B	A, C	21%	100%
68	A, P, B	C	21%	100%
69	C, P, B	A	21%	100%
70	P, B	E, C	21%	100%
71	E, P, B	C	21%	100%
72	C, P, B	E	21%	100%
73	A, C	E, P, B	21%	100%
74	A, E, C	P, B	21%	100%

75	A, C, P	E, B	21%	100%
76	A, E, C, P	B	21%	100%
77	A, C, B	E, P	21%	100%
78	A, E, C, B	P	21%	100%
79	P, B	A, E, C	21%	100%
80	A, P, B	E, C	21%	100%
81	E, P, B	A, C	21%	100%
82	A, E, P, B	C	21%	100%
83	C, P, B	A, E	21%	100%
84	A, C, P, B	E	21%	100%
85	E, C, P, B	A	21%	100%

Association Rules

Association Rules

```

[K] --> [N] (confidence: 1.000)
[Q] --> [A] (confidence: 1.000)
[Q] --> [E] (confidence: 1.000)
[K] --> [D] (confidence: 1.000)
[Q] --> [B] (confidence: 1.000)
[N, S] --> [A] (confidence: 1.000)
[A, S] --> [N] (confidence: 1.000)
[N, J] --> [E] (confidence: 1.000)
[E, J] --> [N] (confidence: 1.000)
[D, P] --> [N] (confidence: 1.000)
[K] --> [N, D] (confidence: 1.000)
[N, K] --> [D] (confidence: 1.000)
[D, K] --> [N] (confidence: 1.000)
[C, O] --> [N] (confidence: 1.000)
[A, C] --> [E] (confidence: 1.000)
[A, O] --> [E] (confidence: 1.000)
[Q] --> [A, E] (confidence: 1.000)
[A, Q] --> [E] (confidence: 1.000)
[E, Q] --> [A] (confidence: 1.000)
[D, B] --> [A] (confidence: 1.000)
[D, H] --> [A] (confidence: 1.000)
[A, C] --> [P] (confidence: 1.000)
[A, C] --> [B] (confidence: 1.000)
[P, B] --> [A] (confidence: 1.000)
[Q] --> [A, B] (confidence: 1.000)
[A, Q] --> [B] (confidence: 1.000)
[B, Q] --> [A] (confidence: 1.000)
[C, P] --> [E] (confidence: 1.000)
[C, B] --> [E] (confidence: 1.000)
[P, B] --> [E] (confidence: 1.000)
[O, B] --> [E] (confidence: 1.000)
[Q] --> [E, B] (confidence: 1.000)
[E, Q] --> [B] (confidence: 1.000)
[B, Q] --> [E] (confidence: 1.000)
[P, B] --> [C] (confidence: 1.000)
[N, A, O] --> [E] (confidence: 1.000)
[N, D, B] --> [A] (confidence: 1.000)
[N, D, C] --> [E] (confidence: 1.000)

```

```

[E, D, C] --> [N] (confidence: 1.000)
[N, C, P] --> [E] (confidence: 1.000)
[N, C, B] --> [E] (confidence: 1.000)
[N, C, J] --> [E] (confidence: 1.000)
[E, C, J] --> [N] (confidence: 1.000)
[N, O, B] --> [E] (confidence: 1.000)
[A, E, D] --> [B] (confidence: 1.000)
[E, D, B] --> [A] (confidence: 1.000)
[A, C] --> [E, P] (confidence: 1.000)
[A, E, C] --> [P] (confidence: 1.000)
[A, C, P] --> [E] (confidence: 1.000)
[A, C] --> [E, B] (confidence: 1.000)
[A, E, C] --> [B] (confidence: 1.000)
[A, C, B] --> [E] (confidence: 1.000)
[P, B] --> [A, E] (confidence: 1.000)
[A, P, B] --> [E] (confidence: 1.000)
[E, P, B] --> [A] (confidence: 1.000)
[A, O, B] --> [E] (confidence: 1.000)
[Q] --> [A, E, B] (confidence: 1.000)
[A, Q] --> [E, B] (confidence: 1.000)
[E, Q] --> [A, B] (confidence: 1.000)
[A, E, Q] --> [B] (confidence: 1.000)
[B, Q] --> [A, E] (confidence: 1.000)
[A, B, Q] --> [E] (confidence: 1.000)
[E, B, Q] --> [A] (confidence: 1.000)
[A, C] --> [P, B] (confidence: 1.000)
[A, C, P] --> [B] (confidence: 1.000)
[A, C, B] --> [P] (confidence: 1.000)
[P, B] --> [A, C] (confidence: 1.000)
[A, P, B] --> [C] (confidence: 1.000)
[C, P, B] --> [A] (confidence: 1.000)
[P, B] --> [E, C] (confidence: 1.000)
[E, P, B] --> [C] (confidence: 1.000)
[C, P, B] --> [E] (confidence: 1.000)
[A, C] --> [E, P, B] (confidence: 1.000)
[A, E, C] --> [P, B] (confidence: 1.000)
[A, C, P] --> [E, B] (confidence: 1.000)
[A, E, C, P] --> [B] (confidence: 1.000)
[A, C, B] --> [E, P] (confidence: 1.000)
[A, E, C, B] --> [P] (confidence: 1.000)
[P, B] --> [A, E, C] (confidence: 1.000)
[A, P, B] --> [E, C] (confidence: 1.000)
[E, P, B] --> [A, C] (confidence: 1.000)
[A, E, P, B] --> [C] (confidence: 1.000)
[C, P, B] --> [A, E] (confidence: 1.000)
[A, C, P, B] --> [E] (confidence: 1.000)
[E, C, P, B] --> [A] (confidence: 1.000)

```

Dari tabel tersebut, terlihat hasil asosiasi rule dengan nilai support 50% dan confident 90%, menghasilkan 85 aturan asosiasi dengan rata-rata nilai support sebesar 21% dan nilai confident 100%. Pembentukan aturan asosiasi memiliki signifikansi penting dalam perolehan dan perhitungan nilai confident. Perlu dicatat bahwa algoritma Apriori cenderung menggunakan memory secara signifikan dan memerlukan waktu eksekusi yang cukup lama saat melakukan pemindaian. Hasil perhitungan asosiasi ini dapat dijadikan panduan untuk menampilkan referensi barang berdasarkan nilai support dan confident terbaik.

D. Simpulan

Berdasarkan kesimpulan hasil penelitian simulasi Algoritma Apriori dan FP-Growth dalam menentukan rekomendasi kodefikasi barang pada transaksi persediaan, dapat disimpulkan bahwa barang yang paling sering dikeluarkan, berdasarkan hasil perhitungan menggunakan Algoritma FP-Growth, antara lain Ballpoint Standar Tecno, refill tissu plastik, Lak Ban Hitam 2 Inchi Merk Daimaru, dan Ballpoint Kenko K1 (0,5). Berdasarkan hasil perhitungan menggunakan Algoritma Apriori dan FP-Growth mampu menghasilkan aturan asosiasi sebanyak 85 aturan, dengan nilai support di atas 50% dan confident 90%. Penerapan metode dengan algoritma Apriori dan FP-Growth dalam Aplikasi SAKTI dapat membantu operator dalam menentukan kodefikasi barang yang sesuai.

Kesimpulan ini mencerminkan manfaat dan potensi penerapan algoritma Apriori dan FP-Growth dalam konteks peningkatan efisiensi dan akurasi manajemen persediaan barang.

Adapun saran untuk penelitian selanjutnya adalah sebagai berikut:

1. Disarankan untuk melakukan pengujian menggunakan algoritma deep learning dengan menambahkan variabel uji yang lebih banyak dan menerapkan metode yang lebih terbaru. Semakin banyak data dan variabel yang digunakan, hasil dan aturan yang diharapkan dapat lebih diperkuat.
2. Selain RapidMiner, sebaiknya penelitian selanjutnya mempertimbangkan penggunaan aplikasi Data Mining lainnya, seperti WEKA, untuk mendapatkan perspektif yang lebih luas dan pemahaman yang lebih mendalam terhadap data yang diolah.

E. Ucapan Terima Kasih

Penulis berterima kasih kepada Hibah Penelitian Sains, Teknologi, dan Seni Universitas Sriwijaya Tahun 2023 dengan Nomor NO.0189.UN9.3.1.SK.2023

F. Referensi

- [1] Powa, J. E. Kaawoan, and F. N. Pangemanan, "Pemanfaatan Teknologi Dan Informasi di Dinas Komunikasi Dan Informatika Statistik Dan Persandian di Kabupaten Minahasa Tenggara," *GOVERNANCE*, vol. 1, no. 2, 2021.
- [2] Peraturan Menteri Keuangan Nomor 203/PMK.05/2019 tentang Perubahan Peraturan Menteri Keuangan Nomor 223/PMK.05/2015 tentang pelaksanaan Piloting Sistem Aplikasi Keuangan Tingkat Instansi (SAKTI).
- [3] Nugroho, H. P., & Lestyowati, J. (2020). Analisis Tingkat Kepuasan dan Kepentingan Pengguna Aplikasi SAKTI dengan PIECES Framework. *Indonesian Treasury Review: Jurnal Perbendaharaan, Keuangan Negara dan Kebijakan Publik*, 5(2), 93-104.
- [4] Ikhsan, M. G. Manajemen Proyek Pengembangan Sistem Aplikasi Keuangan Tingkat Instansi (SAKTI).
- [5] Anwar, A. I., & Hadi, M. (2022). Implementasi aplikasi SAKTI dan SPAN dalam penyusunan laporan keuangan. *Jurnal Informatika*, 1(2), 32-55.
- [6] DWIPUTRI, M. A. (2022). *Tinjauan atas Implementasi Aplikasi SAKTI terhadap Penatausahaan Transaksi Bendahara Pengeluaran di KPPN Bogor* (Doctoral

- dissertation, Politeknik Keuangan Negara STAN).
- [7] Junaidi, A. (2019). Implementasi Algoritma Apriori dan FP-Growth Untuk Menentukan Persediaan Barang. *Jurnal Sisfokom (Sistem Informasi dan Komputer)*, 8(1), 61-67.
 - [8] FEBRIANTI, M. A. (2022). Analisis Pola Pembelian Pelanggan Berdasarkan Transakspenjualan Pada Ritel Dengan Metode Multilevel Association Rules.
 - [9] FIRMANANDA, F. I. (2020). *Penerapan Algoritma Fp-Growth Dan Economy Order Quantity Untuk Menganalisa Pola Belanja Konsumen Di Apotek* (Doctoral dissertation, UNIVERSITAS ISLAM NEGERI SULTAN SYARIF KASIM RIAU).
 - [10] Munanda, E., & Monalisa, S. (2021). PENERAPAN ALGORITMA FP-GROWTH PADA DATA TRANSAKSI PENJUALAN UNTUK PENENTUAN TATALETAK BARANG. *Jurnal Ilmiah Rekayasa dan Manajemen Sistem Informasi*, 7(2), 173-184.
 - [11] Yani, J. A., Mangkunegara, A. A. A. P., & Aditama, R. (1995). Sugiyono. 2017, Metode penelitian kuantitatif, kualitatif, dan R&D. bandung: Alfabeta. *Procrastination And Task Avoidance: Theory, Research and Treatment*. New York: Plenum Press, Yudistira P, Chandra, Diktat Ku.
 - [12] Badrul, M. (2016). Algoritma asosiasi dengan algoritma apriori untuk analisa data penjualan. *Jurnal Pilar Nusa Mandiri*, 12(2), 121-129.
 - [13] Markov, Z., & Larose, D. T. (2007). *Data mining the Web: uncovering patterns in Web content, structure, and usage*. John Wiley & Sons.
 - [14] Rajagukguk, M., Dewi, R., Irawan, E., Hardinata, J. T., & Damanik, I. S. (2020). Implementasi Association Rule Mining Untuk Menentukan Pola Kombinasi Makanan Dengan Algoritma Apriori. *Jurnal Fasilkom*, 10(3), 248-254.
 - [15] Purnia, D. S., & Warnilah, A. I. (2017). Implementasi Data Mining Pada Penjualan Kacamata Menggunakan Algoritma Apriori. *IJCIT (Indonesian Journal on Computer and Information Technology)*, 2(2).
 - [16] Elisa, E. (2018). Market Basket Analysis Pada Mini Market Ayu Dengan Algoritma Apriori. *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 2(2), 472-478.
 - [17] Adha, N., Sianturi, L. T., & Siagian, E. R. (2017). Implementasi Data Mining Penjualan Sabun Dengan Menggunakan Metode Apriori (Studi Kasus: PT. Unilever). *Informasi dan Teknologi Ilmiah (INTI)*, 4(3).
 - [18] Sarath, K. N. V. D., & Ravi, V. (2013). Association rule mining using binary particle swarm optimization. *Engineering Applications of Artificial Intelligence*, 26(8), 1832-1840.
 - [19] Widiastuti, D., & Sofi, N. (2014). Analisis Perbandingan Algoritma Apriori dan FP-Growth pada Transaksi Koperasi. *UG Journal*, 8(1).
 - [20] Triyanto, W. A., Suhartono, V., & Himawan, H. (2014). Analisis Keranjang Pasar Menggunakan K-Medoids dan FP-Growth. *Pseudocode*, 1(2), 129-142.
 - [21] Gunadi, G., & Senses, D. I. (2016). Penerapan metode data mining market basket analysis terhadap data penjualan produk buku dengan menggunakan algoritma apriori dan frequent pattern growth (fp-growth): studi kasus percetakan pt. Gramedia. *Telematika Mkom*, 4(1), 118-132.
 - [22] P.-N. Tan, M. Steinbach, and V. Kumar, *Introduction to Data Mining, (First Edition)*. USA: Addison-Wesley Longman Publishing Co., Inc., 2005.
 - [23] S. D. Patil, R. R. Deshmukh, and D. K. Kirange, "Adaptive Apriori Algorithm for

- frequent itemset mining," in *2016 International Conference System Modeling & Advancement in Research Trends (SMART)*, 2016, pp. 7–13. doi: 10.1109/SYSMART.2016.7894480.
- [24] Liu, S. Zhang, J. Ge, F. Lu, and J. Zou, "Agricultural Major Courses Recommendation Using Apriori Algorithm Applied in China Open University System," in *2016 9th International Symposium on Computational Intelligence and Design (ISCID)*, 2016, vol. 1, pp. 442–446. doi: 10.1109/ISCID.2016.1109.
- [25] E. Erwin, "Analisis market basket dengan algoritma apriori dan fp-growth," *Generic*, vol. 4, no. 2, pp. 26–30, 2009.
- [26] Wang *et al.*, "Comprehensive Association Rules Mining of Health Examination Data with an Extended FP-Growth Method," *Mob. Networks Appl.*, vol. 22, pp. 267–274, 2017, doi: 10.1007/s11036-016-0793-6.