

Penerapan Data Mining Menggunakan Algoritma Fp.Growth Untuk Pengenalan Pola Pembelian Produk Grosir

Aprilia Sulistyohati¹, Opitasari², Siti Anisah³

¹Universitas Indraprasta PGRI, Jakarta, Indonesia

^{2,3}Universitas Indraprasta PGRI, Jakarta, Indonesia
aprilial6891@gmail.com

Abstract: *In the retail business that is growing in Indonesia, the most crucial thing is determining the amount of inventory. The inventory of goods is a determining factor in the success of retail companies. So far, inventory checks have only been carried out manually. So this becomes inefficient when consumers need goods in large quantities and the stock does not meet their needs. The purpose of this study is to apply a data mining method by analyzing consumer purchasing patterns based on sales transaction data. This study uses a mixed-methods design (mix-method) of quantitative and qualitative methods. The material used in this study is product sales transaction data from 2021, which amounted to 1,580 transactions. After cleaning, 594 data points were obtained that were ready to be tested. The tools used for testing are rapidminers. In this study, the author uses the CRISP-DM model, which is used for data mining processing. From the calculation process of the fp-growth algorithm with a minimum support parameter of 10% and a minimum confidence of 50%, the association rules formed are 6 rules. Of all the rules, one was formed with the highest confidence value of 87%, the support value of 12%, and all the rules had a lift ratio value of > 1 , which means that the rule is valid and can be used properly. These results can be used to determine the retail company's sales strategy*

Keywords: *fp-growth, rapidminer, sales transaction*

Abstrak: Dalam bisnis bidang retail yang semakin berkembang di Indonesia hal yang paling krusial yaitu penentuan jumlah persediaan barang. Persediaan barang merupakan faktor penentu dari keberhasilan perusahaan retail. Selama ini pemeriksaan stok barang hanya dilakukan secara manual. Sehingga hal ini menjadi tidak efisien ketika konsumen membutuhkan barang dalam jumlah banyak dan stok tidak memenuhi kebutuhan konsumen. Tujuan dari penelitian ini yaitu untuk menerapkan suatu metode datamining dengan cara menganalisa pola pembelian konsumen berdasarkan data transaksi penjualan. Penelitian ini menggunakan desain metode campuran (*mix-method*) metode kuantitatif dan kualitatif. Bahan yang digunakan dalam penelitian ini yaitu data transaksi penjualan produk tahun 2021 yang berjumlah 1.580 transaksi, dan setelah dilakukan *cleaning* didapat 594 data yang siap diuji. Adapun *tools* yang digunakan untuk pengujian yaitu rapidminer. Dalam penelitian ini penulis menggunakan model CRISP-DM yang digunakan untuk pemrosesan data mining. Dari proses perhitungan algoritma *fp-growth* dengan parameter *minimum support* 10% dan *minimum confidence* 50%, aturan asosiasi yang terbentuk yaitu sebanyak 6 *rules*. Dari semua *rules* terbentuk 1 rule dengan nilai *confidence* tertinggi 87%, nilai *support* 12% dan semua *rules* memiliki nilai *lift ratio* > 1 yang berarti *rule* tersebut bernilai valid dan dapat dimanfaatkan dengan baik. Hasil ini dapat digunakan dalam menentukan strategi penjualan perusahaan retail

Kata kunci: *fp-growth, rapidminer, transaksi penjualan*

Pendahuluan

Pertumbuhan ritel di Indonesia yang sangat pesat memungkinkan semua perusahaan yang bergerak dibidang ritel membuat strategi yang baik untuk dapat menarik konsumen. Fokus perusahaan ritel tidak hanya memusatkan perhatiannya pada penanganan pesaingnya, namun harus juga memperhatikan konsumen yang nantinya akan menentukan keberhasilan usaha yang dijalankan perusahaan ritel. Dalam bisnis di bidang retail hal yang paling krusial yaitu penentuan jumlah persediaan barang. Persediaan barang merupakan faktor penentu dari keberhasilan perusahaan retail dalam mencapai tujuannya, karena kesesuaian apa yang dijual akan berpengaruh terhadap tingkat pendapatan yang berpotensi untuk meningkatkan laba perusahaan (Listiani, A., & Wahyuningsih, 2019).

Persediaan stok barang pada retail merupakan aset yang paling besar yang harus dikelola secara tepat (Chusminah et al., 2019), karena aset ini merupakan kunci dari kesuksesan perusahaan retail dalam mendapatkan laba yang optimal (Murty, Dita Harry. Jazuli, Talitha, 2015). Ritel merupakan kegiatan menjual barang dagang kepada konsumen akhir guna memenuhi kebutuhan sehari-hari dan erat hubungannya dengan pelayanan, promosi, harga serta persediaan barang. Persediaan merupakan salah satu aset yang sangat penting bagi suatu entitas baik bagi perusahaan ritel, manufaktur, jasa, maupun entitas lainnya (Martani, 2016).

Selama ini pemeriksaan stok barang hanya dilakukan secara manual. Sehingga hal ini menjadi tidak efisien ketika konsumen membutuhkan barang dalam jumlah banyak dan stok tidak memenuhi kebutuhan konsumen. Berdasarkan permasalahan di atas penulis tertarik untuk menerapkan suatu metode datamining dengan cara menganalisa pola pembelian konsumen berdasarkan data transaksi penjualan, dimana menghasilkan informasi yang dapat dijadikan sebagai perencanaan dan pengendalian persediaan stok barang.

Penelitian ini bertujuan untuk menemukan pola pembelian terhadap stok barang yang sering dibeli konsumen supaya memudahkan dalam menentukan stok barang yang harus selalu terpenuhi dengan menggunakan metode *FP-Growth*

Metode

Data mining diartikan sebagai pengekstrakan informasi baru yang diambil dari serangkaian data besar yang membantu dalam pengambilan keputusan (Simbolon, 2019) di masa yang akan datang. Dengan adanya Data mining dapat digunakan untuk menemukan pola atau model baru yang lebih dapat dimengerti dan dimanfaatkan untuk mengelola persediaan stok barang. Association rule adalah teknik data mining untuk menemukan aturan asosiatif antara suatu kombinasi item. Algoritma Frequent Pattern Growth (FP-Growth) adalah salah satu alternatif algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sebuah kumpulan data (Ririanti, 2014) (Wang et al., 2017). Maka dari itu algoritma *fp-growth* ini diharapkan dapat menyelesaikan masalah tentang persediaan barang dengan mengasosiasikan barang apa saja yang harus tersedia persediannya (Erwansyah, 2019).

Penelitian ini menggunakan desain metode campuran (*mix-method*) metode kuantitatif dan kualitatif. Adapun *tools* yang digunakan untuk pengujian data yaitu rapidminer. Bahan yang digunakan dalam penelitian ini yaitu data transaksi penjualan produk retail dari 1 tahun terakhir yaitu tahun 2021 yang berjumlah 1.580 transaksi. Penelitian ini menggunakan data primer yang didapatkan melalui observasi secara langsung untuk mengetahui jumlah transaksi harian dari para pembeli, mencari informasi mengenai permasalahan yang sering terjadi serta cara-cara mengantisipasi kehabisan stok produk. Sedangkan data sekunder penulis dapatkan dari paper-paper sejenis. Dalam penelitian ini penulis menggunakan model CRISP-DM (*Cross Industry Standar Process for Data Mining*) yang digunakan untuk pemrosesan data mining. Adapun tahap-tahap CRISP-DM sebagai berikut:

1. Pemahaman bisnis (*Business Understanding*)
2. Pemahaman Data (*Data Understanding*)
3. Pengolahan Data (*Data Preparation*)
4. Pemodelan (*Modeling*)
5. Evaluasi (*Evaluation*)

Hasil dan Pembahasan

Pada penelitian ini ada beberapa tahapan yang akan dibahas, antara lain:

1. Persiapan data

Dalam penelitian ini penulis menggunakan data transaksi penjualan produk pada sebuah retail dengan tujuan untuk menemukan pola penjualan produk retail yang saling berhubungan di dalam suatu transaksi. Dari 1580 data yang didapatkan, lalu dilakukan proses pembersihan data, sehingga didapat 594 *data testing* yang akan digunakan untuk proses pemodelan selanjutnya

2. Representasi data

Data penjualan produk retail dalam penelitian ini terdiri dari 594 transaksi dengan 27 item produk retail. Dari 27 item produk, lalu penulis memberikan label pada masing-masing item supaya lebih mudah dalam mengolah data.

Tabel 1. Pelabelan item produk retail

No	Item produk	Label	No	Item produk	Label
1	Ayam	A	15	Keripik	KR
2	Apel	AP	16	Kentang	KEN
3	Bawang merah	BW	17	Kopi	KO
4	Bawang putih	BP	18	Mie instan	MIE
5	Bumbu kari	BK	19	Minyak goreng	M
6	Buncis	BCS	20	Santan	SAN
7	Beras	BE	21	Pisang	PIS
8	Bumbu opor	BO	22	Susu	SU
9	Bumbu rendang	BR	23	Brokoli	SY
10	Cabai	C	24	Telur	T
11	Gula	G	25	Teh	THE
12	Daging sapi	D	26	Wortel	WOR
13	Ikan	IK	27	Tepung	TP
14	Jeruk	JER			

Setelah dilakukan pelabelan, data transaksi penjualan produk retail siap untuk diolah. Adapun data transaksi penjualan yang sudah siap diolah terdiri dari 594 transaksi dapat dilihat pada table 2.

Tabel 2. Data transaksi penjualan

No transaksi	Item 1	Item 2	Item 3	Item 4	Item 5	No transaksi	Item 1	Item 2	Item 3	Item 4	Item 5
1	WOR	BW	A			...	...	...	...	...	...
2	BW	KEN	BCS	BE	T	...	...	...	...	...	...
3	BRO	WOR	BW	D	BP	578	BRO	WOR	BP	BW	KEN
4	C	WOR	D	BR	BCS	579	BRO	BW			
5	BW	KEN	A	BO	BP	580	WOR	BW			
6	BRO	BW	KEN	D	BCS	581	BRO	BE	C		
7	BRO	WOR	A	KEN	BCS	582	C	WOR	BP	PIS	BW
8	BRO	C	WOR	A	BW	583	WOR	BW	BP	A	KEN
9	BRO	WOR	BR	D	PIS	584	C	KEN	BR	D	BW
10	BRO	BW	D	BR	T	585	KEN	BCS	D		
11	WOR	KEN	A	BO	T	586	BRO	M	BE	A	BCS
12	BRO	WOR	A	BW	BP	587	BRO	C	BCS	BW	PIS
13	BRO	WOR	BK	IK	BCS	588	WOR	BP	KEN	M	BW
14	WOR	KEN	D	BR	T	589	KEN	BW	IK	M	PIS
15	WOR	BW	D	BR	T	590	BRO	C	BE		
16	WOR	KEN	IK	KR	PIS	591	BRO	BW	BP		
17	BRO	WOR	D	BW	KEN	592	BRO	C	BCS	T	
18	BRO	BW	BP	A	KEN	593	BRO	WOR	BP	BE	
19	C	BCS				594	BRO	WOR	BW	T	KEN
20	WOR	BCS									
...	...	...	...	...	...						
...	...	...	...	...	...						

Setelah data sample disiapkan, maka data tersebut akan diubah ke dalam bentuk format binominal yang dapat dilihat pada tabel 3.

Tabel 3. Transaksi penjualan dalam format binominal

Row No.	A	AP	BW	BP	BK	BCS	BE	BO	BR	C	G	D	IK	JER	KR	KEN	KO	ME	M	SAN	PIS	SU	BRO	T	THE	WOR	TP
1	0	0	1	1	0	0	0	0	0	1	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0
2	0	0	1	0	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	1	0	1	1
3	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	1	0	1	0	0
4	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	0
5	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	1	0	0	0	0
6	0	0	1	1	0	0	0	0	0	1	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0
7	0	0	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	0
8	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0	0	0	1	0	0	0	0	0	0	0	1	0
9	0	0	0	0	0	0	0	0	0	1	1	0	0	0	0	1	0	0	0	0	0	1	0	0	0	1	0
10	0	0	1	1	0	1	0	0	0	0	0	0	0	0	0	1	0	0	0	1	0	0	0	0	0	0	0
585	0	0	1	1	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	0	0	0	0	0	0
586	0	0	1	1	0	0	0	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0
587	1	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	0	0	1	0	0
588	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	0	0	0	0
589	1	0	1	1	0	1	0	0	0	0	0	0	0	0	0	0	1	0	0	0	0	0	0	0	1	0	0
590	0	0	0	0	1	0	1	0	0	0	0	0	1	0	0	0	0	0	1	1	0	0	0	0	1	0	0
591	0	0	1	0	0	0	1	0	0	0	0	0	1	0	0	0	0	0	1	0	0	1	0	0	0	0	0
592	0	0	1	1	0	1	0	0	0	0	0	0	1	0	0	0	0	0	0	0	0	0	0	0	1	0	0
593	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	1	0	0	1	0	0	1	0	0
594	0	0	0	0	0	0	0	0	0	0	0	0	1	0	0	1	0	0	0	1	0	0	1	0	0	1	0


Data itemset pada tabel 3 menjelaskan item produk yang dijadikan atribut untuk dieksekusi. Setiap produk yang terjual pada setiap transaksi akan ditandai dengan angka 1 atau bernilai *true* sedangkan untuk produk yang tidak terjual akan ditandai dengan angka 0 atau bernilai *false*

3. Pengujian dengan *tools rapidminer*

Setelah mengubah data transaksi menjadi binominal, maka selanjutnya masuk ke tahap pengujian. Pada penelitian ini, pengujiannya dengan menggunakan aplikasi Rapidminer. Adapun tahapan proses pada rapidminer untuk algoritma FP-Growth dapat digambarkan sebagai berikut:


1. Sebelum pengujian dimulai penulis melakukan import dataset (data_siap_olah.xls) ke dalam rapidminer.
2. Setelah dataset berhasil diimport kemudian penulis memeriksa kesesuaian data dengan kebutuhan proses pengujian, jika data sudah sesuai maka pengujian bisa langsung dilakukan.
3. Untuk mengolah data dengan metode algoritma *fp-growth* pada RapidMiner, memerlukan tiga operator. Operator inilah yang nantinya akan

memproses data secara bertahap. Operator pertama yaitu *numerical to binominal* (untuk mengubah binary ke bilangan binominal). Selanjutnya operator kedua yaitu *FP-growth*, operator ini digunakan untuk menentukan *frequent item set* dengan mengisi parameter nilai *minimum support* dan *minimal confidence*. Untuk menentukan besarnya nilai *minimum support* dan *minimal confidence*, penulis menggunakan acuan dari penelitian sebelumnya, yaitu semakin kecil *minimum support* dan *minimum confidence* yang digunakan maka akurasi yang dihasilkan akan semakin tinggi (Fauzy et al., 2016). Sehingga pada penelitian ini penulis menentukan nilai *minimum support* sebesar 10% atau 0,1 dan nilai *minimum confidence* sebesar 50% atau 0,5. Kemudian relasikan semua operator tersebut seperti gambar 1. Operator ketiga yaitu *create association rule*, operator ini akan menghasilkan aturan asosiasi dari himpunan *frequent item set* yang diberikan.




Gambar 1. Proses relasi atribut pada algoritma *fp-growth*

4. Setelah proses relasi atribut selesai lalu penulis mengatur nilai *minimum support* dan *confidencenya*.



Gambar 2. Nilai minimal support 0,1 dan nilai confidencenya 0,5


5. Hasil dari proses pengujian dataset transaksi penjualan pada rapidminer dapat dilihat pada gambar 3.



No.	Prerequisites	Consequences	Support	Confidence	Lift	Gain	p-value	Lift	Confidence
9	KEN, T	TP	0.131	0.750	0.863	-0.219	0.000	3.205	0.864
9	WOR, BP	BW	0.109	0.750	0.869	-0.100	0.038	1.543	0.869
11	BP	BW	0.109	0.772	0.895	-0.300	0.000	1.577	0.895
16	TP	T	0.109	0.849	0.871	-0.200	0.102	3.023	0.871
16	KEN, TP	T	0.131	0.867	0.862	-0.112	0.000	3.003	0.867
17	WOR, TP	T	0.118	0.875	0.865	-0.102	0.000	3.112	0.875


Gambar 3. Hasil pengujian menggunakan rapidminer

6. Hasil dari pengujian menggunakan rapidminer juga berupa *fp-tree*. *Fp-tree* merupakan tampilan grafis *rules* dari dataset transaksi penjualan.



Gambar 4. Hasil pengujian rapidminer berupa *fp-tree*

7. Untuk mengetahui aturan asosiasi yang terbentuk dari proses pengujian pada RapidMiner. Maka aturan asosiasi yang terbentuk seperti gambar 5.



Association Rules	Confidence	Support
[WOR, BP] ==> [BW]	0.756	0.109
[TP] ==> [T]	0.849	0.109
[KEN, TP] ==> [T]	0.867	0.131
[WOR, TP] ==> [T]	0.875	0.118
[BP] ==> [BW]	0.772	0.109
[KEN, T] ==> [TP]	0.750	0.131

Gambar 5. Hasil deskripsi *association rules* dari pengujian rapidminer

Pembahasan

Setelah menjalankan proses untuk mencari *Association rule* pada data set transaksi penjualan produk retail. Algoritma *fp-growth* dapat menghasilkan suatu aturan asosiasi. Dengan menentukan nilai *minimum support* sebesar 10% dan menentukan *minimum confidence* sebesar 50%. Maka terbentuk 6 aturan asosiasi yang memenuhi nilai *minimum support* dan *minimum confidence*. Aturan yang terbentuk adalah sebagai berikut :

1. Jika konsumen membeli kentang dan telur maka akan membeli tepung dengan nilai *support* 13% dan *confidence* 75%. Artinya konsumen yang membeli kentang dan telur mempunyai kemungkinan 75% akan membeli tepung aturan ini didukung 13% dari total transaksi. Dengan *lift ratio* >1 yaitu 3.205, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.
2. Jika konsumen membeli wortel dan bawang putih maka akan membeli bawang merah dengan nilai *support* 10% dan *confidence* 75%. Artinya konsumen yang membeli wortel dan bawang putih mempunyai kemungkinan 75% akan membeli bawang merah aturan ini didukung 10% dari

total transaksi. Dengan *lift ratio* >1 yaitu 1.543, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.

3. Jika konsumen membeli bawang putih maka akan membeli bawang merah dengan nilai *support* 18% dan *confidence* 77%. Artinya konsumen yang membeli bawang putih mempunyai kemungkinan 77% akan membeli bawang merah aturan ini didukung 18% dari total transaksi. Dengan *lift ratio* >1 yaitu 1.577, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.
4. Jika konsumen membeli tepung maka akan membeli telur dengan nilai *support* 19% dan *confidence* 85%. Artinya konsumen yang membeli tepung mempunyai kemungkinan 85% akan membeli telur aturan ini didukung 19% dari total transaksi. Dengan *lift ratio* >1 yaitu 3.020, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.
5. Jika konsumen membeli kentang dan tepung maka akan membeli telur dengan nilai *support* 13% dan *confidence* 87%. Artinya konsumen yang membeli wortel dan bawang putih mempunyai kemungkinan 87% akan membeli bawang merah aturan ini didukung 13% dari total transaksi. Dengan *lift ratio* >1 yaitu 3.083, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.
6. Jika konsumen membeli wortel dan tepung maka akan membeli telur dengan nilai *support* 12% dan *confidence* 87%. Artinya konsumen yang membeli wortel dan bawang putih mempunyai kemungkinan 87% akan membeli bawang merah aturan ini didukung 12% dari total transaksi. Dengan *lift ratio* >1 yaitu 3.112, maka dapat dinyatakan bahwa aturan ini valid dan memiliki keterkaitan satu sama lain.

Hasil akhir yang diperoleh dari *rule* tersebut adalah sebuah pengetahuan baru tentang pola pembelian konsumen yang selama ini jarang diketahui. Hal itu dapat dimanfaatkan untuk membantu perusahaan retail agar dapat menjaga kualitasnya dengan baik kepada konsumen, dengan cara produk makanan harus tetap tersedia saat konsumen membutuhkannya. Untuk itu perusahaan harus selalu menyediakan stok produk yang diinginkan oleh konsumen. Selain itu hasil aturan yang didapatkan dapat digunakan untuk pembuatan program paket hemat untuk menambah pendapatan retail (Harahap & Nastuti, 2019). Hasil penelitian ini juga dapat digunakan sebagai rekomendasi pihak manajemen dalam melakukan pengaturan tata letak display barang-barang retail (Munanda & Monalisa, 2021).

Kesimpulan

Berdasarkan hasil penelitian maka dapat diambil kesimpulan bahwa penerapan data mining untuk menganalisa pola penjualan produk grosir dengan menggunakan metode algoritma *fp-growth* dapat diterapkan dengan baik dan mampu menghasilkan suatu aturan asosiasi dari data set transaksi penjualan kombinasi produk grosir yang sering dibeli konsumen secara bersamaan dalam satu transaksi. Dari proses perhitungan algoritma *fp-growth* dengan parameter *minimum support*

10% dan *minimum confidence* 50%, aturan asosiasi yang terbentuk yaitu sebanyak 6 *rule*. Dari 6 *rule* yang terbentuk ditemukan 2 *rule* dengan nilai *confidence* tertinggi yaitu sebagai berikut :

1. Jika konsumen membeli kentang dan tepung maka akan membeli telur dengan nilai *support* 13% dan *confidence* 87%.
2. Jika konsumen membeli wortel dan tepung maka akan membeli telur dengan nilai *support* 12% dan *confidence* 87%.

Dari semua *rules* tersebut memiliki nilai *lift ratio* >1 yang berarti *rule* tersebut bernilai valid dan dapat dimanfaatkan dengan baik. Hasil ini dapat digunakan dalam menentukan strategi penjualan seperti membuat paket harga produk grosir serta dapat meminimalisir terbuangnya produk-produk yang kurang laku, selain itu perusahaan retail tersebut dapat mengurangi stok sayuran yang kurang diminati konsumen dan menambah stok sayuran yang paling banyak diminati konsumen .

Ucapan Terima Kasih

Penulis ingin mengucapkan terima kasih yang sebesar-besarnya pada semua pihak yang membantu dalam pengambilan data serta pelaksanaan penelitian kami. Terutama kepada civitas akademika Universitas Indraprasta PGRI yang telah mendukung penuh terselesaikannya artikel ini.

Referensi

- Chusminah, C., Haryati, A., & Nelfianti, F. (2019). Efektivitas Pengelolaan Persediaan Barang Dengan Sistem Safety Stock Pada PT X di Jakarta. *Jurnal Economic Resource*, 2(1), 1–13. <https://doi.org/10.33096/jer.v2i1.230>
- Erwansyah, K. (2019). Implementasi Data Mining Untuk Menganalisa Hubungan Data Penjualan Produk Bahan Kimia Terhadap Persedian Stok Barang Menggunakan Algoritma FP (Frequent Pattern) Growth Pada PT . Grand Multi Chemicals. *Jurnal Teknologi Sistem Informasi Dan Sistem Komputer TGD (J-SISKO TECH)*, 2(2), 30–40.
- Fauzy, M., Saleh W, K. R., & Asror, I. (2016). Penerapan Metode Association Rule Menggunakan Algoritma Apriori Pada Simulasi Prediksi Hujan Wilayah Kota Bandung. *Jurnal Ilmiah Teknologi Infomasi Terapan*, 2(3). <https://doi.org/10.33197/jitter.vol2.iss3.2016.111>
- Harahap, S. Z., & Nastuti, A. (2019). Teknik Data Mining Untuk Penentuan Paket Hemat Sembako. *Jurnal Ilmiah Fakultas Sains Dan Teknologi*, 2(3), 111–119.
- Listiani, A., & Wahyuningsih, S. . (2019). Analisis Pengelolaan Persedian Barang Dagang Untuk Mengoptimalkan Laba. *STIE Kesuma Negara Blitar*, 4(1), 97. <https://journal.stieken.ac.id/index.php/peta/article/view/378/481>
- Martani, D. (2016). *Akuntansi Keuangan Menengah Berbasis PSAK* (2nd ed.). Salemba Empat.
- Munanda, E., & Monalisa, S. (2021). Penerapan Algoritma Fp-Growth Pada Data Transaksi Penjualan Untuk Penentuan Tataletak. *Jurnal Ilmiah Rekayasa Dan Manajemen Sistem Informasi*, 2(2), 173–184. <http://ejournal.uin-suska.ac.id/index.php/RMSI/article/view/13253>
- Murty, Dita Harry. Jazuli, Talitha, T. (2015). Optimasi Pengendalian Persediaan Bahan Baku Di PT. Bromindo Mekar Mitra. *Jurnal Teknik Industri, Fakultas Teknik, Universitas Dian Nuswantoro*.
- Ririanti. (2014). Implementasi Algoritma Fp-Growth Pada Aplikasi Prediksi Persediaan Sepeda Motor (Studi Kasus Pt . Pilar Deli Labumas). *Pelita Inform. Budi Darma*, 6(1), 139–144.
- Simbolon, P. H. (2019). Implementasi Data Mining Pada Sistem Persediaan Barang Menggunakan Algoritma Apriori (Studi Kasus: Srikandi Cash Credit Elektronik dan Furniture). *Jurnal Riset Komputer*, 6(4), 401–406.
- Wang, C.-H., Zheng, L., Yu, X., & Zheng, X. (2017). Using Fuzzy FP-Growth for Mining Association Rules. *131(Icoi)*, 328–332. <https://doi.org/10.2991/icoi-17.2017.47>