



Implementasi Algoritma *FP-Growth* Untuk Menentukan Pola Pembelian Konsumen Pada Data Transaksi Penjualan PT Ligno Specialty *Chemicals*

Riska Tajrian, Catur Eri Gunawan*, Gusmelia Testiana

Universitas Islam Negeri Raden Fatah Palembang, Indonesia

*e-mail korespondensi: caturerig@radenfatah.ac.id

Abstract. Business competition in Indonesia is currently getting strict, especially in the manufacturing industry. PT ligno Specialty chemicals is a chemical industry company that applies the B2B model in their target market. PT Ligno must maintain relationships with customers such as fulfilling customer demand for the stock of goods to be purchased. However, determining the amount of inventory for sales stock is not an easy thing. At PT Ligno in determining the amount of inventory is only based on mere estimates and on the other side there is sales transaction data that has not been optimally utilized. So that an alternative solution in this study is to use the data mining method with the FP-Growth algorithm to find out the association rule between goods. This study aims to determine consumer purchase patterns based on sales transaction data for 2018-2021 and evaluate the results of association rules using lift ratios. The results showed that the FP-Growth algorithm can be applied to determine consumer purchasing patterns in PT Ligno's sales transactions. There are 8 association rules that meet the minimum support of 5% and the minimum confidence of 80%, and consumers tend to buy items FGC-C043, FGC-C029, and FGC-C042 simultaneously, and also on items FGC-C012 and FGC-C013. The rules with the highest support, confidence, and lift ratio values are if you buy FGC-C043 items, you also buy FGC-C029 and FGC-C042 items with a support value of 6.3%, confidence of 100%, and lift ratio of 14,458. The results of the evaluation of the combination of minimum support and minimum confidence, show that there are four rules with an lift ratio of less than . So that overall, the rules generated in the FP-Growth algorithm in addition to the four rules are valid if they are used as a reference in determining inventory.

Keyword: Data Mining; FP-Growth; Inventory; Consumer Purchase Patterns

Abstrak. Persaingan bisnis di Indonesia saat ini semakin ketat terutama di industri manufaktur. PT Ligno Specialty *Chemicals* merupakan perusahaan industri kimia yang menerapkan model B2B dalam target pasarnya. PT Ligno harus menjaga hubungan terhadap pelanggan seperti memenuhi permintaan pelanggan atas stok barang yang akan dibeli. Akan tetapi menentukan jumlah persediaan barang untuk stok penjualan bukanlah hal yang mudah. Pada PT Ligno dalam menentukan jumlah persediaan barang hanya berdasarkan perkiraan belaka dan di sisi lain terdapat data transaksi penjualan yang belum dimanfaatkan secara optimal. Sehingga alternatif solusi pada penelitian ini yaitu memanfaatkan metode data *mining* dengan algoritma *FP-Growth* untuk mengetahui *association rules* antar barang. Penelitian ini bertujuan menentukan pola pembelian konsumen berdasarkan data transaksi penjualan tahun 2018-2021 dan mengevaluasi hasil *association rules* menggunakan *lift ratio*. Hasil penelitian menunjukkan algoritma *FP-*



Growth dapat diterapkan untuk menentukan pola pembelian konsumen pada transaksi penjualan PT Ligno. Terdapat 8 *association rules* yang memenuhi minimum *support* 5% dan minimum *confidence* 80%, dan konsumen cenderung membeli item FGC-C043, FGC-C029, dan FGC-C042 secara bersamaan, dan juga pada item FGC-C012 dan FGC-C013. Adapun *rules* dengan nilai *support*, *confidence*, dan *lift ratio* tertinggi yaitu jika membeli item FGC-C043 maka juga membeli item FGC-C029 dan FGC-C042 dengan nilai *support* 6,3%, *confidence* 100%, dan *lift ratio* 14,458. Hasil evaluasi terhadap kombinasi minimum *support* dan minimum *confidence*, menunjukkan terdapat empat *rules* dengan *lift ratio* kurang dari satu. Sehingga secara keseluruhan, *rules* yang dihasilkan pada algoritma *FP-Growth* selain ke empat *rules* tersebut valid jika dijadikan acuan dalam penentuan persediaan barang.

Kata kunci: *Data Mining; FP-Growth; Persediaan Barang; Pola Pembelian Konsumen*

PENDAHULUAN

Persaingan bisnis di Indonesia saat ini semakin ketat terutama di industri manufaktur. Industri manufaktur yang mengalami peningkatan produksi pada triwulan IV tahun 2019 yaitu industri kimia, yang meningkat 13,07% jika dibandingkan pada triwulan III tahun 2019 [1]. Dengan adanya kenaikan produksi tersebut maka tidak dapat dipungkiri persaingan bisnis di industri kimia akan semakin kompetitif pula. Oleh karena itu, sebuah bisnis harus memiliki inovasi dan perbaikan terhadap masalah agar mampu bersaing di pangsa pasar. Salah satu permasalahan operasional yang sering dihadapi perusahaan manufaktur yaitu di bagian *inventory* atau persediaan barang.

PT Ligno *Specialty Chemicals* (LSC) termasuk perusahaan industri kimia yang berlokasi di kota Tangerang, Banten. Dalam target pasarnya PT Ligno menerapkan model *Business to Business* (B2B), yaitu pemasarannya ditujukan ke perusahaan lain seperti perusahaan *precast*, *readymix* dan kontraktor, bukan untuk konsumen umum [2]. Sebagai perusahaan manufaktur yang menerapkan model B2B, PT Ligno harus menjaga hubungan terhadap pelanggan seperti memenuhi permintaan atas stok barang yang akan dibeli. Akan tetapi menentukan jumlah persediaan barang untuk stok penjualan bukanlah hal yang mudah. Jika *inventory* atau persediaan barang terlalu besar dan permintaan pelanggan rendah, maka kerugian akan terjadi karena menyiapkan ruang penyimpanan yang lebih untuk barang yang tidak laku terjual. Kemudian potensi terjadinya penyusutan nilai guna barang terutama produk kimia, dan biaya perawatan tambahan lainnya [3]. Pada PT Ligno untuk menentukan jumlah persediaan barang berdasarkan data sales dan hanya melalui perkiraan manajer produksi saja. Dari penerapan strategi tersebut masih terjadi permasalahan karena penentuan jumlah stok barang belum sesuai dengan permintaan pelanggan di lapangan.

Upaya yang bisa diterapkan perusahaan dalam menentukan persediaan stok yang ideal yaitu dengan menganalisa kumpulan data transaksi penjualan menggunakan teknik data *mining* [3]. Dari kumpulan data transaksi penjualan inilah perusahaan dapat menganalisa keranjang pasar (*market basket analysis*), sehingga ditemukan pola pembelian konsumen dan diketahui barang apa saja yang sering dibeli bersamaan [4]. Setiap tahunnya PT Ligno memiliki sekitar 600 *invoice* data transaksi penjualan. Jika diakumulasikan dalam 4 tahun yaitu dari tahun 2018-2021, PT Ligno mempunyai ribuan data transaksi penjualan yang hanya disimpan dalam basis data dan untuk laporan penjualan saja. Padahal dari



kumpulan data transaksi penjualan tersebut bisa digali kembali untuk mendapatkan pengetahuan dan informasi baru, dan teknik data *mining* merupakan pilihan yang sangat tepat untuk mengolah data transaksi penjualan lebih lanjut lagi.

Teknik data *mining* yang digunakan untuk menganalisis keranjang pasar adalah *association rules*. *Association rules* adalah teknik data *mining* yang digunakan untuk mencari korelasi atau hubungan dari pola yang penting dan menarik dalam kumpulan data yang besar [5]. Terdapat beberapa algoritma yang digunakan untuk menemukan *association rules*, salah satunya adalah algoritma *Frequent Pattern-Growth (FP-Growth)*. Algoritma *FP-Growth* dipilih karena mempunyai kelebihan yang menjadikannya efisien dibandingkan algoritma lain (algoritma *Apriori*) yaitu karena menggunakan konsep *divide and conquer* dimana data dibagi menjadi setiap *subset*, konsep *FP-Tree* sehingga tidak lagi membutuhkan *generate candidate*, dan dalam pencarian *frequent itemset* hanya memindai *database* sebanyak dua kali [6]. Penelitian tentang pencarian pola asosiasi dengan perbandingan algoritma *Apriori* dan *FP-Growth*, dan hasil menunjukkan algoritma *FP-Growth* menemukan *association rules* lebih banyak, dengan tingkat akurasi yang lebih besar daripada *apriori* dan pemrosesan yang lebih cepat [7]. Kemudian *FP-Growth* memiliki tingkat akurasi yang lebih baik dibandingkan *Apriori* yaitu sebesar 128%, dengan *support* 1,68 [8].

Kemudian terdapat penelitian terdahulu terkait penerapan algoritma *FP-Growth* untuk menentukan pola pembelian konsumen menggunakan data *mining*. Penelitian tentang penerapan *FP-Growth* untuk menganalisa hubungan data penjualan terhadap persediaan stok barang, menghasilkan 6 *association rules* menggunakan 21 sampel data transaksi, dengan *minsup* 10% dan *minconf* 50%. Dari pola penjualan tersebut dapat dijadikan acuan dalam *inventory* bahan kimia sehingga dapat menjamin ketersediaan stok untuk barang yang terkait [3]. Kemudian penelitian untuk mengetahui pola beli konsumen dan menjaga stabilitas stok barang pada minimarket, menghasilkan 10 *strong association rules* dengan sampel 20 data transaksi. Adapun *minsup* dan *minconf* yang digunakan adalah 30% dan 70%. Dari pola tersebut dapat menjadi informasi dalam memprediksi tingkat ketersediaan stok barang [9]. Selain itu penelitian untuk menemukan pola peminjaman buku dan melakukan perbandingan pola dengan nilai minimum *support* dan *confidence* yang berbeda dengan 209 data transaksi. Hasil menunjukkan nilai *minsup* dan *minconf* mempengaruhi terhadap jumlah *rule* yang dihasilkan [10].

Kemudian evaluasi atau pengukuran terhadap kekuatan *association rules* juga perlu dilakukan, karena pengukuran menggunakan *support* dan *confidence* tidaklah cukup untuk melihat kekuatan hubungan antar item. Sehingga diperlukan perhitungan korelasi untuk mengukur *valid* atau tidaknya *rule* yang dihasilkan [11]. Pada penelitian ini metode yang digunakan untuk mengukur kekuatan hasil *association rules* adalah *lift ratio*. *Lift ratio* merupakan perhitungan korelasi yang paling sederhana dan akurat untuk mengukur kekuatan hasil *association rules* [12]. Nilai *confidence* saja tidak cukup untuk mengetahui kekuatan *association rules*, karena *confidence* hanya dapat mencapai nilai 1 saja, sedangkan nilai *lift ratio* tak terhingga [13].

Berdasarkan beberapa penelitian terdahulu dan apa yang telah dijelaskan diatas, maka penelitian ini bertujuan untuk mengetahui pola pembelian konsumen



yang terbentuk dari pengolahan data transaksi penjualan dengan algoritma *FP-Growth*. Selain itu penelitian ini juga bertujuan untuk menganalisis valid atau tidak hasil *association rules* dari kombinasi nilai minimum *support* dan minimum *confidence* menggunakan metode *lift ratio*. Adapun jumlah data transaksi penjualan yang akan dianalisa yaitu dari tahun 2018-2021 dengan menggunakan beberapa atribut penting seperti *transaction id* dan *item no*.

METODOLOGI PENELITIAN

Metode Penelitian

Penelitian ini menggunakan metode kualitatif dengan pendekatan deskriptif. Penelitian kualitatif bertujuan menunjukkan pola hubungan yang interaktif, memperoleh pemahaman makna dan melakukan analisis untuk mencari pola, model, thema, dan teori [14]. Metode kualitatif yang dilakukan akan dijelaskan dengan pendekatan deskriptif. Pendekatan deskriptif merupakan usaha untuk mendeskripsikan atau menjelaskan suatu gejala, peristiwa, atau kejadian yang terjadi [15].

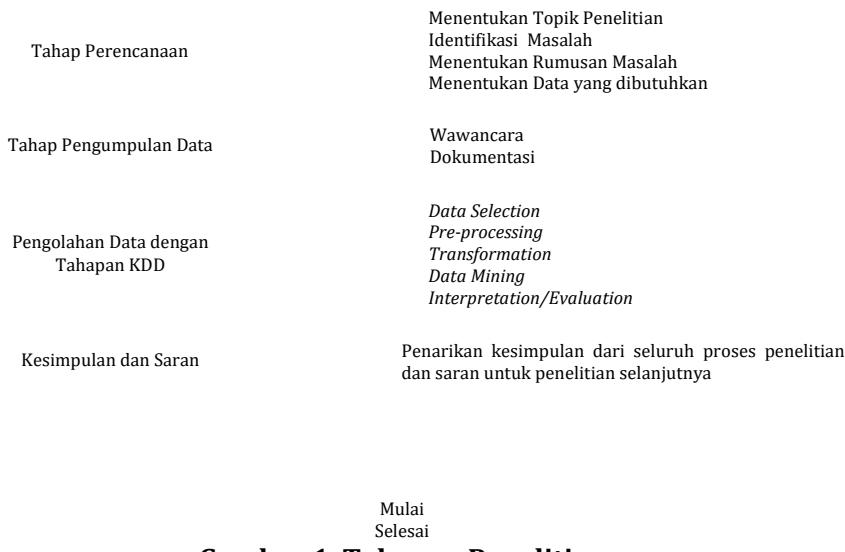
Kebutuhan Penelitian

Kebutuhan yang digunakan pada penelitian, yang akhirnya diolah menjadi landasan yaitu:

1. Data transaksi penjualan PT Ligno *Specialty Chemicals* tahun 2018-2021
2. *Tools RapidMiner* untuk proses pengolahan data *mining*

Tahapan Penelitian

Penelitian ini terdiri dari empat tahap yaitu tahap perencanaan, tahap pengumpulan data, tahap pengolahan data dengan proses KDD, dan tahap kesimpulan dan saran. Gambar 1 berikut menggambarkan tahapan dalam penelitian ini.



Gambar 1. Tahapan Penelitian

Pada gambar 1 diatas menjelaskan tahapan proses penelitian yang akan menggambarkan penelitian secara keseluruhan. Tahapan yang akan dilakukan yaitu:



1. Tahap perencanaan, yaitu menentukan topik penelitian dan mengidentifikasi masalah yang terjadi pada tempat atau objek penelitian. Adapun topik pada penelitian ini adalah pengolahan *data mining* dengan algoritma *FP-Growth* untuk menentukan pola pembelian konsumen.
2. Tahap pengumpulan data, yaitu dengan cara wawancara terhadap manajer *sales* dan *marketing* pada PT Ligno. Selanjutnya pengumpulan data dengan metode dokumentasi untuk mengambil data sekunder berupa arsip data transaksi penjualan PT Ligno di dalam *database* sistem penjualan.
3. Pengolahan data dengan tahapan KDD. KDD terdiri dari lima tahap, yaitu tahap *data selection*, tahap *pre-processing*, tahap *transformation*, tahap *data mining*, dan tahap *interpretation/evaluation*. KDD dipilih pada penelitian ini karena banyak digunakan oleh para peneliti dan data mining *expert*, selain itu juga digunakan untuk mencari pola yang ada terhadap data [16].
4. Tahap kesimpulan dan saran, yaitu dilakukan penarikan kesimpulan dari seluruh proses penelitian dan hasil yang didapatkan.

HASIL DAN PEMBAHASAN

Tahap Data Selection

Data yang digunakan dalam penelitian ini adalah data transaksi penjualan PT Ligno yaitu dari tahun 2018-2021, dengan jumlah *record* dataset awal pada data mentah yaitu 2.482 data dan terdiri dari tiga atribut yaitu *invoice date*, *customer no.*, dan *item no.*. Akan tetapi pada perhitungan algoritma *FP-Growth* terdapat atribut yang harus ditambahkan yaitu atribut *transaction id* (TID). *Transaction id* (TID) digunakan sebagai *identifier* unik untuk menandai setiap transaksi dalam dataset, yang nantinya dapat membantu proses pencarian *itemset* yang ber-frequent [12]. Tabel 4.1 menampilkan sampel data transaksi penjualan PT Ligno yang telah ditambahkan atribut *transaction id* (TID).

Tabel 1. Sampel Data Transaksi Penjualan PT Ligno

TID	Invoice Date	Customer No.	Item No
1	03 Jan 2018	K017	FGC-R004
2	04 Jan 2018	C002-IDR	FGC-S001
3	04 Jan 2018	D008b	FGC-R002
4	05 Jan 2018	H014a	FGC-C003
5	05 Jan 2018	S048	FGC-C010
...
2.48	31 Dec 2021	S016	FGC-F012
2			FGC-F014

Pada tahap seleksi dilakukan pemilihan terhadap atribut yang digunakan untuk tahap selanjutnya yaitu atribut *transaction id* (TID) dan atribut *item no.*. Atribut tersebut dipilih karena memberikan pengaruh terhadap perhitungan algoritma *FP-Growth* dan mengandung informasi terkait item-item yang dibeli oleh pelanggan [12].

Tahap Pre-Processing



Pada tahap *pre-processing* dilakukan integrasi data yaitu menggabungkan data transaksi dari tahun 2018-2021 ke dalam satu file yang sama, sehingga menghasilkan total data secara keseluruhan sebanyak 2.482 data. Selanjutnya dilakukan *cleaning* data yaitu membersihkan data-data yang kosong atau *missing value*, data yang tidak relevan dan redundan, sehingga bisa diolah untuk ke tahap selanjutnya.

Kemudian jika produk yang dibeli konsumen hanya terdiri satu item, maka data transaksi yang seperti itu tidak akan diolah, karena berdasarkan prinsip *anti-monotipe heuristic* yaitu membuang data yang hanya mengandung satu transaksi [17]. Setelah dilakukan tahap *pre-processing*, semula data yang jumlahnya 2.482 kemudian berkurang menjadi 347 data.

Tabel 2. Jumlah Data Transaksi Setelah di *Cleaning Data*

Tahun	Total Transaksi	Transaksi dengan 2 Item/Lebih
2018	616	79
2019	601	43
2020	535	75
2021	730	150
Jumlah	2482	347

Kemudian pada tabel 3 berikut menampilkan sampel data transaksi yang telah dilakukan tahap *pre-processing* atau data yang mengandung 2 item atau lebih pada setiap transaksi.

Tabel 3. Data Transaksi Setelah Tahap *Pre-Processing*

TID	Item No.
15	FGC-R019
	FGC-R018
	FGC-R021
	FGC-R022
	FGC-R020
	FGC-S001
27	FGC-R004
	FGC-R006
41	FGC-C012
	FGC-C013
248	...
	...
	FGC-
	H003
2	FGC-
	H004

Tahap Transformation

Selanjutnya data transaksi ditransformasikan menjadi tabulasi bilangan biner dan diberikan kode atau inisialisasi data untuk mempermudah pengolahan data *mining*.

Tabel 4. Inisialisasi pada Atribut Item No

No	Item No.	Inisial Item
1	FGC-	A01



No .	Item No.	Inisial Item
2	C003 FGC-C006	A02
3	FGC-C007	A03
4	FGC-C008	A04
5	FGC-C010	A05
...
66	NV	A66

Inisialisasi item akan diterapkan pada data transaksi penjualan yang sudah dilakukan tahap *pre-processing*. Tabel 5 menampilkan data transaksi penjualan dengan menggunakan inisial item pada atribut *item no.*

Tabel 5. Data Transaksi Setelah Tahap Transformation

TID	Item No.
15	A59
	A58
	A61
	A62
27	A60
	A65
41	A52
	A54
...	A07
	A08
248	...
2	A39
	A41

Selain melakukan inisialisasi terhadap item, pada data transaksi juga akan dilakukan transformasi menjadi format data tabular yang berisi angka 1 dan 0. Dengan ketentuan jika produk tersebut dibeli oleh konsumen maka ditandai dengan angka 1 atau bernilai *true*, sedangkan untuk produk yang tidak dibeli akan ditandai dengan angka 0 atau bernilai *false* pada atribut item. Hasil transformasi ini nantinya diperlukan untuk implementasi data *mining* menggunakan *tools RapidMiner*.

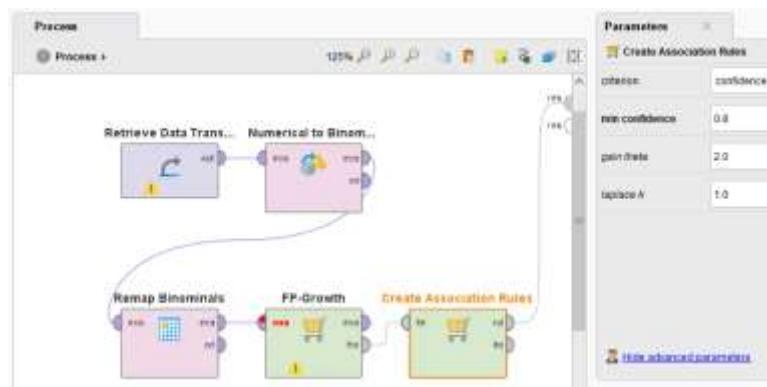
Tabel 6. Transformasi Data Transaksi

TID	A01	A02	A03	A04	A05	A06	A07	A08	A09	A10	A11	A12	A13	A14	A15	...	A66
15	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...	0
27	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...	0
41	0	0	0	0	0	0	1	1	0	0	0	0	0	0	0	...	0
44	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...	0
53	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...	0
...
2482	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	...	0

Tahap Data Mining

Implementasi Algoritma FP-Growth dengan Tools RapidMiner

Data yang digunakan untuk perhitungan dengan tools *RapidMiner* adalah data transaksi yang sudah melalui tahap *transformation* dengan format tabular seperti pada tabel 6 dengan format *xls (excel)*. Data tersebut disimpan dan *import* ke dalam *tools RapidMiner*. Selanjutnya data diproses dengan menggunakan perintah operator yang terdapat pada menu proses. Gambar 2 berikut menampilkan operator-operator yang digunakan dalam *RapidMiner* untuk menghasilkan *association rules*.



Gambar 2. Operator-Operator yang digunakan pada *RapidMiner*

Operator *retrieve* digunakan untuk meng-*input* data transaksi yang sudah tersimpan pada *local repository* ke dalam menu proses. Operator *numerical to binomial* untuk mengubah tipe data pada atribut, yaitu pada atribut A01-A66 diubah tipe datanya menjadi *binomial*, sedangkan untuk atribut TID tipe datanya tetap *integer*. Operator *remap binominals* untuk menentukan nilai positif dan negatif dari atribut yang telah diseleksi, dimana nilai 1 untuk *positive value* dan nilai 0 untuk *negative value*. Operator *FP-Growth* digunakan untuk memasukkan nilai minimum *support* pada menu *parameters* dan operator *create association rules* untuk mengetahui hasil *association rules*.

Dalam penelitian ini telah ditentukan nilai minimum *support* nya adalah 0,05 atau 5% dan minimum *confidence* nya 0,8 atau 80%. Saat ini belum ada aturan baku terkait penentuan nilai minimum *support* dan *confidence*, sehingga *user* dapat menentukan nilai minimum *support* itu sendiri [18], akan tetapi penentuan tersebut dapat didasarkan pada tujuan penelitian dari analisis *association rules* [12]. Sehingga pada penelitian ini ditetapkan nilai minimum *support* yang digunakan adalah 0,05 atau 5%. Sedangkan nilai minimum *confidence* dipilih 80% agar tingkat akurasi atas *rule* yang dihasilkan memiliki akurasi yang tinggi dan termasuk *strong association rules* [19].

Setelah ditentukan nilai minimum support dan minimum confidence pada operator dan dilakukan run, maka pada menu result menampilkan 8 *association rules* yang memenuhi *minsup* 5% dan *minconf* 80%. Adapun hasil *association rules* tersebut dapat dilihat pada gambar 3 berikut.



Association Rules

```
Association Rules
[A28] --> [A17] (confidence: 0.800)
[A17, A28] --> [A29] (confidence: 0.917)
[A08] --> [A07] (confidence: 0.931)
[A29] --> [A17] (confidence: 1.000)
[A29] --> [A28] (confidence: 1.000)
[A29] --> [A17, A28] (confidence: 1.000)
[A17, A29] --> [A28] (confidence: 1.000)
[A28, A29] --> [A17] (confidence: 1.000)
```

Gambar 3. Hasil Association Rules

Tahap Evaluation

Pada tahap ini dilakukan pengujian atau evaluasi terhadap *association rules* untuk mengukur kuat tidaknya *association rules* yang telah terbentuk pada perhitungan algoritma *FP-Growth*. Pada penelitian ini evaluasi atau pengujian akan menggunakan *lift ratio*, karena *lift ratio* merupakan perhitungan korelasi yang paling sederhana dan akurat untuk mengukur kekuatan hasil *association rules* [12]. Pada tahap sebelumnya telah didapatkan 8 *association rules* yang memenuhi *minsup* 5% dan *minconf* 80%, maka selanjutnya menghitung *lift ratio* dan gambar berikut menunjukkan hasil perhitungan *lift ratio* pada *Rapid Miner*.

Premises	Conclusion	Support	Confidence	Lift
A28	A17	0.069	0.800	3.559
A17, A28	A29	0.063	0.917	14.458
A28	A07	0.078	0.931	3.713
A29	A17	0.063	1	4.448
A29	A29	0.063	1	11.567
A29	A17, A28	0.063	1	14.458
A17, A28	A28	0.063	1	11.567
A28, A29	A17	0.063	1	4.449

Gambar 4. Hasil Perhitungan Lift Ratio Pada RapidMiner

Berdasarkan perhitungan *lift ratio* diatas, hasil menunjukkan semua 8 *association rules* tersebut bernilai *lift ratio* >1. Ketika *lift ratio* antar dua item dalam sebuah transaksi menunjukkan nilai lebih besar dari 1, maka terdapat korelasi positif antara item A dan B [12]. Artinya *rules* tersebut valid atau kuat jika dijadikan acuan dalam pengambilan keputusan.

Sehingga dari perhitungan akhir tersebut didapatkan pola pembelian konsumen dengan menggunakan 347 data transaksi yang telah melalui tahap *pre-processing*, dengan menggunakan nilai minimum *support* 5% dan minimum *confidence* 80% dan menghasilkan 8 *association rules*. Berikut penjabaran dari 8 *association rules* tersebut:

1. Jika membeli item FGC-C042 (A28) maka juga membeli item FGC-C029 (A17) dengan nilai *support* 6,9%, nilai *confidence* 80%, dan nilai *lift ratio* 3,559.
2. Jika membeli item FGC-C029 (A17) dan item FGC-C042 (A28) maka juga membeli item FGC-C043 (A29) dengan nilai *support* 6,3%, nilai *confidence* 91,7%, dan nilai *lift ratio* 14,458.



3. Jika membeli item FGC-C013 (A08) maka juga membeli item FGC-C012 (A07) dengan nilai *support* 7,8%, nilai *confidence* 93,1%, dan nilai *lift ratio* 3,713.
4. Jika membeli item FGC-C043 (A29) maka juga membeli item FGC-C029 (A17) dengan nilai *support* 6,3%, nilai *confidence* 100%, dan nilai *lift ratio* 4,449.
5. Jika membeli item FGC-C043 (A29) maka juga membeli item FGC-C042 (A28) dengan nilai *support* 6,3%, nilai *confidence* 100%, dan nilai *lift ratio* 11,567.
6. Jika membeli item FGC-C043 (A29) maka juga membeli item FGC-C029 (A17) dan item FGC-C042 (A28) dengan nilai *support* 6,3%, nilai *confidence* 100%, dan nilai *lift ratio* 14,458.
7. Jika membeli item FGC-C029 (A17) dan item FGC-C043 (A29) maka juga membeli item FGC-C042 (A28) dengan nilai *support* 6,3%, nilai *confidence* 100%, dan nilai *lift ratio* 11,567.
8. Jika membeli item FGC-C042 (A28) dan item FGC-C043 (A29) maka juga membeli item FGC-C029 (A17) dengan nilai *support* 6,3%, nilai *confidence* 100%, dan nilai *lift ratio* 4,449.

Dilihat dari pola pembelian diatas, dari 8 *association rules* tersebut konsumen cenderung membeli item FGC-C043, FGC-C029, dan FGC-C042 secara bersamaan, dan juga pada item FGC-C012 dan FGC-C013. Adapun *rule* dengan nilai *support*, nilai *confidence* dan nilai *lift ratio* tertinggi yaitu pada *rule* jika membeli item FGC-C043 (A29) maka juga membeli item FGC-C029 (A17) dan item FGC-C042 (A28) dengan nilai *support* 6,3%, *confidence* 100%, dan *lift ratio* 14,458.

Kemudian evaluasi atau pengujian terhadap kombinasi nilai minimum *support* dan minimum *confidence* juga dilakukan, yaitu untuk mengetahui pengaruh nilai minimum *support* dan *confidence* terhadap jumlah *rule* yang dihasilkan dan mengukur kekuatan pada setiap *rules*.

Tabel 7. Hasil Pengujian dengan Kombinasi Minsup dan Minconf

Minimum Confidence												
M	0,0	0,1	0,2	0,3	0,4	0,5	0,6	0,7	0,8	0,9	1	
i	1	12	11	94	87	78	53	41	27	17	5	
n	1	1	0									
i	0,0	94	89	81	74	70	49	39	25	15	1	
m	2										3	
m	0,0	30	29	24	22	20	17	15	11	8	6	
u	3											
m	0,0	22	22	18	16	14	11	11	9	7	5	
S	4											
u	0,0	22	22	18	16	14	11	11	9	7	5	
p	5											
p	0,0	18	18	14	12	11	10	10	8	7	5	
o	5											
r	0,0	16	16	13	11	11	10	10	8	7	5	
t	6											
r	0,0	16	16	13	11	11	10	10	8	7	5	
t	7											
t	0,0	2	2	2	1	1	1	1	1	1	0	
8	8	0	0	0	0	0	0	0	0	0	0	



	0,0	0	0	0	0	0	0	0	0	0	0
9											
0,1	0	0	0	0	0	0	0	0	0	0	0

Pada tabel 7 menunjukkan semakin tinggi nilai minimum *support* dan nilai minimum *confidence*, maka *rules* yang dihasilkan akan semakin sedikit dan juga semakin akurat. Selain itu dari seluruh *hasil association rules*, hanya terdapat empat *rules* yang memiliki nilai *lift ratio* kurang dari satu yaitu pada *rules* dengan *minsup* 0,01 dan 0,02 dan *minconf* 0,1 dan 0,2. Sehingga secara keseluruhan, *rules* yang dihasilkan pada algoritma *FP-Growth* selain ke empat *rules* tersebut valid apabila dijadikan acuan dalam penentuan persediaan barang karena memiliki nilai *lift ratio* lebih dari satu. Adapun *rules* dengan nilai *lift ratio* kurang dari satu dapat dilihat pada gambar 5 berikut.

Premises	Conclusion	Support	Confidence	Lift ↑
A33	A07	0.012	0.200	0.798
A12	A17	0.014	0.185	0.824
A17	A03	0.026	0.115	0.977
A03	A17	0.026	0.220	0.977

Gambar 5. Association Rules dengan Nilai Lift Ratio < 1

KESIMPULAN

Algoritma *FP-Growth* dapat diterapkan untuk menentukan pola pembelian konsumen pada transaksi penjualan PT Ligno. Pola yang terbentuk dari minimum *support* 5% dan minimum *confidence* 80% menghasilkan 8 *association*. Adapun *rule* dengan nilai *support*, nilai *confidence* dan nilai *lift ratio* tertinggi yaitu pada *rule* jika membeli item FGC-C043 (A29) maka juga membeli item FGC-C029 (A17) dan item FGC-C042 (A28) dengan nilai *support* 6,3%, *confidence* 100%, dan *lift ratio* 14,458. Kemudian pengujian terhadap kombinasi nilai minimum *support* dan nilai minimum *confidence* menunjukkan hasil bahwa semakin tinggi nilai keduanya, maka jumlah *rules* yang dihasilkan akan semakin sedikit, namun memiliki tingkat keakuratan yang tinggi karena hubungan antar item yang semakin kuat. Selain itu berdasarkan pengujian *lift ratio* terhadap keseluruhan *association rules*, hanya terdapat 4 *rules* dengan nilai *lift ratio* kurang dari 1. Sehingga secara keseluruhan, *rules* yang dihasilkan dari algoritma *FP-Growth* kecuali ke empat *rules* tersebut valid apabila dijadikan acuan oleh PT Ligno dalam penentuan persediaan barang.

Kemudian berdasarkan penelitian yang telah dilakukan, yang menjadi *limitation* pada penelitian ini yaitu karena PT Ligno termasuk perusahaan *B2B* yang memasarkan produknya ke perusahaan lain, bukan ke konsumen umum dan juga pembelian produk dilakukan dalam jumlah yang besar. Sehingga pembelian terhadap dua item produk atau lebih, jarang terjadi pada PT Ligno. Seperti pada data transaksi penjualan dari tahun 2018-2021, dari total dataset awal sebanyak 2.482 data, hanya terdapat 347 data yang mengandung dua item atau lebih pada data transaksi. Sehingga hal tersebut mempengaruhi terhadap hasil penelitian, dimana pola pembelian konsumen yang dihasilkan hanya mempunyai kombinasi item sebanyak dua sampai tiga item.

Daftar Rujukan

- [1] Badan Pusat Statistik. Pertumbuhan Produksi Industri Manufaktur Triwulan IV



- 2019 [Internet]. Berita Resmi Statistik (No.14/02/Th. XXIII); 2020. Available from: <https://www.bps.go.id/pressrelease/2020/02/03/1739/pertumbuhan-produksi-ibs-tahun-2019-naik-4-01-persen-dibandingkan-tahun-2018.html>
- [2] Hutt MD, Speh TW. Business Marketing Management: B2B [Internet]. Tenth Edit. South-Western Cengage Learning; 2021 [cited 2022 Oct 13]. Available from: <http://dspace.vnbrims.org:13000/jspui/bitstream/123456789/4877/1/Business%20Marketing%20Management%20B2B.pdf>
- [3] Erwansyah K. Implementasi Data Mining Untuk Menganalisa Hubungan Data Penjualan Produk Bahan Kimia Terhadap Persediaan Stok Barang Menggunakan Algoritma FP (Frequent Pattern) Growth Pada PT. Grand Multi Chemicals. *J Teknol Sist Inf dan Sist Komput TGD* [Internet]. 2019 Jul 18 [cited 2022 Sep 7];2(2):30–40. Available from: <https://ojs.trigunadharma.ac.id/index.php/jsk/article/view/123>
- [4] Firman CE. Penentuan Pola Yang Sering Muncul Untuk Penjualan Pupuk Menggunakan Algoritma FP-Growth. *Inform J Inform Manaj dan Komput* [Internet]. 2019 Jan 10 [cited 2022 Sep 7];9(2):1–8. Available from: <http://ejournal.stmikdumai.ac.id/index.php/path/article/view/97>
- [5] Dunham MH. Data Mining: Introductory and Advanced Topics. Pearson Education India; 2006.
- [6] Sidhu S, Meena UK, Nawani A, Gupta H, Thakur N. FP Growth Algorithm Implementation. *Int J Comput Appl.* 2014;93(8).
- [7] Salam A, Zeniarja J, Wicaksono W, Kharisma L. Pencarian Pola Asosiasi Untuk Penataan Barang Dengan Menggunakan Perbandingan Algoritma Apriori Dan Fp-Growth (Study Kasus Distro Epo Store Pemalang). *Dinamik* [Internet]. 2018 Jun 17 [cited 2022 Sep 8];23(2):57–65. Available from: <https://www.unisbank.ac.id/ojs/index.php/fti1/article/view/7178>
- [8] Anggrawan A, Mayadi M, Satria C. Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan Algoritma FP-Growth. *MATRIX J Manajemen, Tek Inform dan Rekayasa Komput* [Internet]. 2021 Nov 26;21(1):125–38. Available from: <https://journal.universitasbumigora.ac.id/index.php/matrik/article/view/1260>
- [9] Nelisa, Halim SHA. Identifikasi Pola Penjualan Kategori Barang dalam Menjaga Stabilitas Stok Barang Menggunakan Algoritma Fp-Growth. *J Inform Ekon Bisnis* [Internet]. 2021 Dec 30 [cited 2022 Sep 8];3(4):155–60. Available from: <https://infeb.org/index.php/infeb/article/view/94>
- [10] Kadafi M. Penerapan Algoritma FP-Growth Untuk Menemukan Pola Peminjaman Buku Perpustakaan UIN Raden Fatah Palembang. *MATICS J Ilmu Komput dan Teknol Inf (Journal Comput Sci Inf Technol)* [Internet]. 2018 Mar 22 [cited 2022 Sep 8];10(2):52–8. Available from: <http://ejurnal.uin-malang.ac.id/index.php/saintek/article/view/5628>
- [11] Mahendra KA, Khusnuliawati H, Charolina A. Penerapan Data Mining Pada Peminjaman Buku di Perpustakaan Universitas Sahid Surakarta Menggunakan Algoritma FP-Growth. Universitas Sahid Surakarta; 2018.
- [12] Han J, Pei J, Tong H. Data Mining: Concepts And Techniques. Morgan kaufmann; 2022.
- [13] Takdirillah R. Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan. *Edumatic J Pendidik Inform.* 2020;4(1):37–46.
- [14] Siyoto S, Sodik MA. Dasar Metodologi Penelitian. Literasi Media Publishing; 2015.
- [15] Arikunto S. Prosedur Penelitian Suatu Pendekatan Praktik. Jakarta : Rineka Cipta; 2013.
- [16] Shafique U, Qaiser H. A Comparative Study of Data Mining Process Models (KDD, CRISP-DM and SEMMA). *Int J Innov Sci Res* [Internet]. 2014 Nov 20 [cited 2023 Mar 6];12(1):217–22. Available from: <http://www.ijisr.issr.net>



- journals.org/abstract.php?article=IJISR-14-281-04
- [17] Putri NC. Implementasi Algoritma FP-Growth Untuk Mencari Aturan Asosiasi dan Menentukan Stok Barang Pada Toko Rotte Bakery [Internet]. 2021. Available from: <http://repository.uin-suska.ac.id/53563/>
- [18] Hikmawati E, Maulidevi NU, Surendro K. Minimum threshold determination method based on dataset characteristics in association rule mining. J Big Data [Internet]. 2021 Dec 1 [cited 2022 Dec 14];8(1):1-17. Available from: <https://journalofbigdata.springeropen.com/articles/10.1186/s40537-021-00538-3>
- [19] Zaida M. Penerapan Metode Frequent Pattern-Growth (FP-Growth) Untuk Mencari Pola Penggunaan Internet Pada Anak Sekolah Dasar Terhadap Pekerjaan Orang Tua [Internet]. Universitas Islam Negeri Sultan Syarif Kasim Riau; 2017. Available from: <http://repository.uin-suska.ac.id/18113/>