

PREDIKSI STOK DAN PENGATURAN TATA LETAK BARANG MENGGUNAKAN KOMBINASI ALGORITMA *TRIPLE EXPONENTIAL SMOOTHING* DAN *FP-GROWTH*

Kristoko Dwi Hartomo^{*1}, Sri Yulianto², Rahmat Abadi Suharjo³

^{1,2,3} Universitas Kristen Satya Wacana

Email: ¹ kristoko@uksw.edu, ² sri.yulianto@uksw.edu, ³ 672015035@student.uksw.edu

^{*}Penulis Korespondensi

(Naskah masuk: 07 Maret 2019, diterima untuk diterbitkan: 05 Oktober 2020)

Abstrak

Persaingan bisnis semakin meningkat khususnya dalam bidang *retail*. Hal ini mengharuskan pemilik melakukan inovasi terhadap bisnisnya. Pemilik swalayan perlu melakukan inovasi untuk melakukan perbaikan tata letak barang dan perbaikan stok, karena konsumen seringkali mengalami kesulitan dalam pencarian barang dan pihak swalayan sering mengalami kekurangan dan kelebihan stok barang. Salah satu hal yang perlu diperhatikan oleh pemilik untuk mempertahankan dan menambah konsumen yaitu dengan melakukan pendekatan dengan konsumen. Pendekatan pada konsumen digunakan untuk mengenali dan memahami perilaku, kebutuhan dan keinginan konsumen. Berdasarkan permasalahan tersebut, maka tujuan penelitian adalah untuk mengoptimalkan pengaturan tata letak barang dan optimalisasi persediaan stok barang. Dalam penelitian ini menggunakan data penjualan yang diolah sehingga menghasilkan informasi untuk pemilik swalayan. Pengolahan data dalam penelitian ini disebut *data mining* dengan menggunakan algoritma *FP-Growth* dan *Triple Exponential Smoothing*. Algoritma *FP-Growth* digunakan untuk mengetahui pola perilaku konsumen sehingga dapat digunakan untuk pengambilan keputusan dalam penyusunan barang dan algoritma *Triple Exponential Smoothing* yang merupakan algoritma prediksi digunakan untuk pengaturan stok barang. Dalam penelitian ini dengan menggunakan algoritma *FP-Growth* menemukan 12 aturan asosiasi, aturan asosiasi yang memiliki nilai *lift ratio* paling tinggi adalah teh dan gula dengan nilai *lift ratio* 6.131 dan dengan algoritma *Triple Exponential Smoothing* diperoleh hasil prediksi pada bulan Januari 2018 adalah 131,141 kg dengan tingkat akurasi MAPE 88,3 %.

Kata kunci: *Analysis, Data Mining, FP-Growth, Triple Exponential Smoothing*

STOCK PREDICTION AND ITEM LAYOUT ARRANGEMENT USING A COMBINATION OF *TRIPLE EXPONENTIAL SMOOTHING* AND *FP-GROWTH* ALGORITHM

Abstract

Business competition is increasing especially in the retail sector. This requires the owner to innovate his business. The shop owner wants to make an invasion to repair goods and equipment, because consumers are in dire need of things and supermarkets often occur. One of the things that need to be considered by the owner to maintain and add consumers is by approaching consumers. Use of information to recognize and understand consumer needs and desires. By overcoming it, the purpose of the research is to regulate the procedures for goods and optimize the preparation of stock items. In this study using processed sales data. Information on information for shop owners. Data processing in this research is called data mining using *FP-Growth* and *Triple Exponential Smoothing* algorithms. *FP-Growth* algorithm to find out user behavior patterns can be used to develop *Triple Exponential Smoothing* decisions and algorithms which are forecasting algorithms for inventory items. In this study using the algorithm *FP-Growth* found 12 association rules, which have the highest lift ratio is Tea and sugar with a lift ratio of 6.131 and with *Triple Exponential Smoothing* algorithm, the forecasting result in January 2018 is 131.141 Kg with 88,3 % MAPE accuracy.

Keywords: *Analysis, Data Mining, FP-Growth, Triple Exponential Smoothing*

1. PENDAHULUAN

Kemunculan pesaing yang begitu banyak membuat pemilik swalayan harus berpikir dan melakukan inovasi agar dapat bersaing. Persaingan sejenis akan mendorong swalayan untuk melakukan inovasi guna mempertahankan dan menambah konsumen perusahaan. Salah satu hal yang perlu diperhatikan oleh perusahaan untuk mempertahankan dan menambah konsumen yaitu dengan melakukan pendekatan dengan konsumen. Pendekatan pada konsumen digunakan untuk mengenali dan memahami perilaku, kebutuhan dan keinginan konsumen. Pengetahuan tentang perilaku konsumen dapat digunakan untuk optimalisasi tata letak barang dan optimalisasi stok barang (Agung dan Nurhadiyono, 2015).

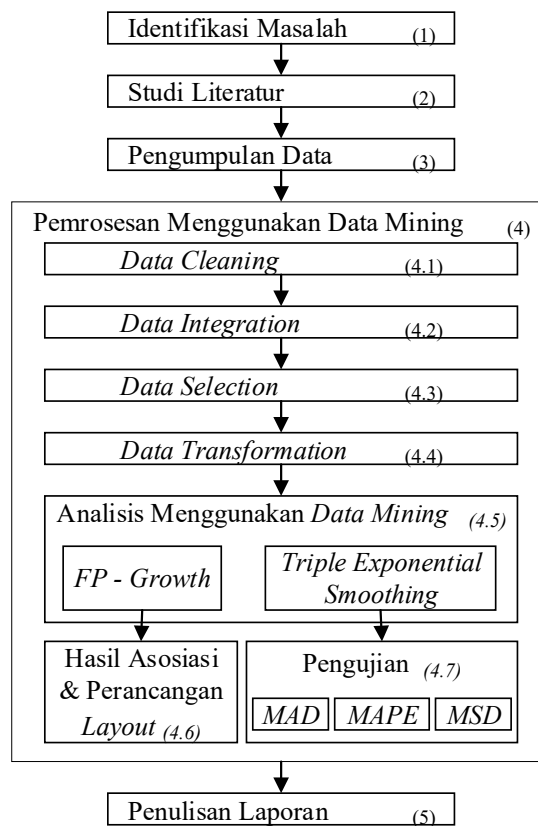
Indomaret, Alfamart, B-Mart, X-Stationery, dan Persada Swalayan merupakan perusahaan *retail* yang sudah menggunakan pendekatan pola konsumen untuk pengaturan tata letak barang dan stok barang (Bilqisth, 2016) (Tamara, 2016) (Hidayah, 2015) (Utami & Atmojo, 2017). Masalah yang timbul dari manajemen swalayan adalah pengaturan tata letak barang masih berdasarkan subyektif manajemen saja, jadi terdapat beberapa barang yang seharusnya tidak pantas / cocok disandingkan. Dari tata letak yang terkesan berantakan menimbulkan kesulitan oleh para konsumen dalam pencarian barang. Dengan kondisi seperti itu menyebabkan para konsumen berpindah ke swalayan lain yang memiliki penataan lebih rapi. Pada swalayan ini pengolahan stok barang masih menggunakan perkiraan tanpa memanfaatkan data yang ada, seringkali banyak barang yang kosong dan bahkan terjadi penumpukan barang yang mengakibatkan penghambatan perputaran modal.

Data transaksi penjualan yang terjadi setiap harinya semakin lama semakin menumpuk, data tersebut sangat tidak bermanfaat jika tidak diolah. Data transaksi dapat digunakan untuk mengetahui pola perilaku konsumen. Pengetahuan tentang pola perilaku belanja dapat dimanfaatkan untuk menyusun tata letak barang sehingga memberikan kemudahan bagi konsumen dalam melakukan pembelian dan dapat meningkatkan kemungkinan munculnya keinginan membeli atau *impulse buying* (Agung dan Nurhadiyono, 2015).

Penelitian sebelumnya memperlihatkan permasalahan yang terjadi pada tata letak barang dan persediaan barang dapat mengakibatkan penurunan penjualan maupun menghambat perputaran modal. Riset ini dilakukan untuk menyelesaikan masalah pengaturan tata letak barang dan prediksi stok barang menggunakan algoritma *FP-Growth* dan *Triple Exponential Smoothing*. Kedua metode tersebut cocok digunakan dalam pemecahan masalah terkait optimalisasi tata letak barang dan prediksi stok barang.

2. METODE PENELITIAN

Dalam penelitian ini ada beberapa langkah yang harus dilakukan agar sesuai dengan tujuan. Tahapan penelitian yang digunakan dapat dilihat pada Gambar 1.



Gambar 1. Tahapan Penelitian

Tahapan penelitian pada gambar 1 diawali dengan tahap 1 yaitu mengidentifikasi masalah, pada tahap ini dilakukan identifikasi terhadap permasalahan yang ada pada penataan barang di beberapa swalayan, masalah yang ditemukan adalah penataan barang dan penentuan barang yang tidak optimal menyebabkan beberapa jenis barang tidak laku bahkan tidak dilihat oleh pelanggan. Masalah tersebut merupakan masalah yang dapat diselesaikan dengan metode *market basket analysis* dan prediksi.

2.1. Studi Literatur

Tahapan selanjutnya adalah tahap 2 yaitu melakukan studi literatur jurnal-jurnal yang memiliki riset area yang sama, berdasarkan penelitian yang berjudul Penerapan Algoritma *Apriori* dan *FP-Growth* untuk Mengenali Pola Pembelian Pelanggan pada Elmart Swalayan, penelitian ini menganalisis pola pembelian di Elmart Swalayan. Penelitian ini membandingkan dua algoritma yaitu algoritma *Apriori* dan *FP-Growth*, kedua algoritma ini dilakukan pengujian dengan data yang sama dan menghasilkan aturan yang sama pula. Perbedaan dari kedua algoritma tersebut adalah

waktu komputasi, waktu komputasi dari Algoritma *FP-Growth* lebih cepat dibandingkan dengan algoritma *Apriori*. Penelitian ini juga melakukan pengujian *lift ratio* yang menunjukkan bahwa salah satu aturan yang dihasilkan oleh kedua algoritma memiliki kekuatan asosiasi yang besar yaitu 2,06 (Tarigan, Lestari & Wardhani, 2017).

Berdasarkan penelitian yang berjudul Implementasi *Data Mining* Dengan Menggunakan Algoritma *FP-Growth* untuk Menentukan Pola Penjualan Barang Pada Event Tertentu (Studi Kasus: Berkah Swalayan), penelitian ini menganalisis pola perilaku konsumen terhadap pembelian di swalayan Berkah menggunakan data transaksi penjualan. Tujuan dari penelitian ini adalah mengenali pola pembelian pelanggan berdasarkan kecenderungan produk yang muncul dalam data transaksi penjualan serta dapat melihat produk yang sering dibeli oleh pelanggan. Kesimpulan dari penelitian ini yaitu mengidentifikasi barang-barang yang dibeli secara bersamaan kemudian digunakan untuk mengatur tata letak barang. Penelitian ini menghasilkan 6 aturan barang yang saling berkaitan, barang yang paling banyak dibeli oleh pelanggan adalah ABC Juice Jambu 250ml (Ikhsana, Sihabudin & Lestari, 2015).

Berdasarkan penelitian yang berjudul Perbandingan Metode *Holt Exponential Smoothing* dan *Winter Exponential Smoothing* Untuk Peramalan Penjualan *Souvenir*. Penelitian ini dilakukan di UD. Fajar Jaya yang merupakan unit usaha dagang yang bergerak pada bidang penyediaan *souvenir*. Dalam penjualan *souvenir*, seringkali UD. Fajar Jaya mengalami kekosongan stok *souvenir* ketika pesanan membludak di waktu-waktu tertentu. Hal ini terjadi karena tidak terdapat analisa dan strategi manajemen stok (tidak dapat memprediksi berapa jumlah optimal *souvenir* yang harus disediakan) yang dilakukan oleh eksekutif UD. Fajar Jaya. Untuk mengatasi hal tersebut, maka dilakukan prediksi terhadap tingkat penjualan *souvenir* dengan menggunakan metode *Holt* dan *Winter* yang ada pada pengembangan metode *Exponential Smoothing* (ES). Dari penerapan kedua metode tersebut, kemudian dibuat perbandingan efektifitas metode yang diukur melalui akurasi data aktual dan hasil prediksi dengan cara mengetahui tingkat kesalahan prediksi. Dari hasil penelitian diperoleh hasil prediksi untuk metode *Holt Exponential Smoothing* bulan Juli tahun 2017 adalah sebesar 599 item yang mungkin akan terjual dengan tingkat kesalahan prediksi MAPE sebesar 20.5%. Sedangkan untuk prediksi menggunakan metode *Winter Exponential Smoothing* pada bulan Juli tahun 2017 adalah sebesar 549.6 item yang mungkin akan terjual dengan tingkat kesalahan MAPE sebesar 12.6% (Utami & Atmojo, 2017).

Berdasarkan penelitian yang berjudul Prediksi Jumlah Penumpang Pada *Siluet Tour And Travel* Kota Malang Menggunakan Metode *Triple*

Exponential Smoothing. Penelitian ini dilakukan prediksi jumlah penumpang pada *Siluet Tour and Travel*, yaitu salah satu perusahaan yang bergerak dalam bidang jasa *tour dan travel*. Karena data jumlah penumpang mengandung unsur musiman, prediksi pada penelitian ini menggunakan metode *Triple Exponential Smoothing*. Tahapan yang dilakukan pada proses prediksi meliputi *input* data, uji data, proses perhitungan dan *output*. Hasil dari pengolahan *dataset* digunakan untuk perhitungan proses ramalan yang menghasilkan MAPE=9,86 $\alpha=0,4$ $m=1$ dengan hasil prediksi jumlah penumpang pada bulan November 2015 adalah 501 (Fitria & Hartono, 2017).

Berdasarkan lima penelitian tersebut, maka penelitian ini memiliki beberapa perbedaan. Perbedaan mendasar yaitu objek studi kasus yang berbeda dengan riset sebelumnya, pada riset ini menggunakan kombinasi dua algoritma yaitu *FP-Growth* dan *Triple Exponential Smoothing*. Kontribusi dalam riset ini sebagai pedoman pemecahan masalah dalam kasus prediksi stok dan tata letak barang.

2.2. Data Mining

Riset menggunakan pendekatan *data mining*, *data mining* adalah proses yang menggunakan teknik statistik, matematika, kecerdasan buatan dan *machine learning* untuk mengekstraksi dan mengidentifikasi informasi yang bermanfaat dan pengetahuan yang terkait dari berbagai basis data besar (Kusrini, 2009). *Data mining*, sering juga disebut *knowledge discovery in database* (KDD), adalah kegiatan yang meliputi pengumpulan, pemakaian data historis untuk menemukan keteraturan, pola atau hubungan dalam *dataset* berukuran besar. Keluaran dari *data mining* ini bisa dipakai untuk memperbaiki pengambilan keputusan di masa depan. Sehingga istilah *pattern recognition* jarang digunakan karena termasuk bagian dari *data mining* (Santosa, 2007).

Market basket analysis adalah suatu metodologi untuk melakukan analisis *buying habit* konsumen dengan menemukan asosiasi antar beberapa item yang berbeda, yang diletakkan konsumen dalam *shopping basket* (keranjang belanja) yang dibeli pada suatu transaksi tertentu. Tujuan dari *market basket analysis* adalah untuk mengetahui produk-produk mana yang mungkin akan dibeli secara bersamaan (Han & Kamber, 2000).

Association rule merupakan teknik *data mining* untuk mencari pola hubungan dalam data atau basis data yang paling populer adalah *Market Basket Analysis* (MBA). *Association rule* adalah salah satu metode yang bertujuan mencari pola yang sering muncul di antara banyak transaksi, di mana setiap transaksi terdiri dari beberapa item (Widodo, 2008).

Ide dari aturan asosiasi adalah untuk memeriksa semua kemungkinan hubungan *if-then*

antar item dan memilih hanya yang paling mungkin (*most likely*) sebagai indikator dari hubungan ketergantungan antar item. Biasanya digunakan istilah *antedecent* untuk mewakili bagian “jika” dan *consequent* untuk mewakili bagian “maka”. Dalam analisis ini, *Antedecent* dan *consequent* adalah sekelompok item yang tidak punya hubungan secara bersama (Santosa, 2007).

Algoritma *FP-Growth* merupakan salah satu algoritma dari teknik *association rule* yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul (*frequent itemset*) dalam sebuah kumpulan data. Pengembangan dari algoritma apriori ini terletak dalam scanning *database* dan akurasi aturannya. *FP-Growth* lebih memberikan keuntungan karena hanya dilakukan satu atau dua kali saja *scanning database* sedangkan apriori perlu melakukan *scanning database* berulang ulang. Pada *apriori* akurasi aturannya lebih tinggi daripada *FP-Growth*, namun karena *scanning* yang dilakukan berulang membuat kecepatan lebih lambat. Walaupun begitu, kedua algoritma ini memiliki tujuan yang sama yaitu menentukan *frequent itemset* (Arifin, 2015).

Penggalan *itemset* yang *frequent* dengan menggunakan algoritma *FP-Growth* akan dilakukan dengan cara membangkitkan struktur data *tree* atau disebut dengan *FP-Tree*. Metode *FP-Growth* dapat dibagi menjadi 3 tahapan utama yaitu sebagai (Han & Kamber, 2006):

- Tahap pembangkitan *conditional pattern base*.
- Tahap pembangkitan *conditional FP-Tree*.
- Tahap pencarian *frequent itemset*.

2.3. Exponential Smoothing

Metode prediksi *exponential smoothing* merupakan sekelompok metode yang menunjukkan pembobotan menurun secara *exponential* terhadap nilai pengamatan yang lebih tua. Dalam metode ini terdapat satu atau lebih parameter yang ditentukan secara eksplisit, dan hasil pilihan ini menentukan bobot yang dikenakan pada nilai observasi (Makridakis, Wheelwright & McGee, 1999). *Triple Exponential Smoothing* adalah salah satu jenis metode prediksi *exponential smoothing* yang merupakan perluasan dari metode *Holt (Double Exponential Smoothing)*. Metode ini dipopulerkan oleh *Winter*. Metode ini menambahkan nilai faktor musim pada persamaan dasar dari *smoothing*. Dalam perhitungannya terdapat dua cara yaitu *additif* dan *multipikatif*. Disini akan digunakan cara *multipikatif*, dengan rumus yang ditunjukkan pada persamaan 1, 2, 3, 4 (Santoso, 2009):

a. Komponen level estimate

$$L_t = \alpha \frac{y_t}{s_t} + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (1)$$

b. Komponen trend estimate

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (2)$$

c. Komponen Seasonality estimate

$$S_t = \gamma \frac{y_t}{t} + (1 - \gamma)S_t - p \quad (3)$$

d. Untuk Forecast pada periode ke p

$$\hat{Y}_{t-p} = (L_t + pT_t)S_t - s + p \quad (4)$$

Dimana :

L= *Level estimate* (dipengaruhi oleh besaran α)

T= *Trend estimate* (dipengaruhi oleh besaran β)

S= *Seasonality estimate* (dipengaruhi oleh besaran γ)

P= Periode musiman

\hat{Y} = Nilai *forecast* untuk periode mendatang

Metode ini membutuhkan nilai α, β, γ sebagai nilai parameter pemulusan. Bobot nilai tersebut lebih tinggi diberikan kepada data yang lebih baru, sehingga nilai parameter yang sesuai akan memberikan ramalan yang optimal dengan nilai kesalahan (*error*) terkecil. Untuk mendapatkan nilai α, β, γ yang tepat, pada umumnya dilakukan dengan *trial and error* (coba-coba) untuk menentukan nilai kesalahan terendah. Nilai α dilakukan dengan membandingkan menggunakan interval pemulusan antar $0 < \alpha < 1$, yaitu α (0,1 sampai dengan 0,9). Metode ini cocok digunakan untuk data yang mengandung unsur trend dan musim dengan pola data tidak stasioner (Santoso, 2009). Metode *Exponential Smoothing* telah dipergunakan dalam prediksi curah hujan (Hartomo, 2005), harga ternak (Wu, 2016), permintaan pasar (Tratar, 2016), dan produksi kaos (Darmawan, 2018).

Salah satu cara mengevaluasi teknik prediksi adalah menggunakan ukuran tentang tingkat perbedaan antara hasil prediksi dengan permintaan yang sebenarnya terjadi. Ada tiga ukuran yang biasa digunakan, yaitu :

- *Mean Absolute Deviation*, MAD merupakan rata-rata kesalahan mutlak selama periode tertentu tanpa memperhatikan apakah hasil prediksi lebih besar atau lebih kecil dibandingkan kenyataannya. Secara matematis, MAD dirumuskan seperti pada persamaan 10 (Nasution & Prasetyawan, 2008).
- *Mean Absolute Percentage Error*, MAPE merupakan ukuran kesalahan relatif. MAPE biasanya lebih berarti dibandingkan MAD, karena MAPE menyatakan persentase kesalahan hasil prediksi terhadap permintaan aktual selama periode tertentu yang akan memberikan informasi persentase kesalahan terlalu tinggi atau terlalu rendah. Secara matematis, MAPE dirumuskan seperti pada persamaan 11 (Nasution & Prasetyawan, 2008).
- *Mean Squared Deviation*, MSD merupakan ketepatan nilai dugaan model, yang dinyatakan dalam rata-rata kuadrat dari kesalahan, secara matematis, MAD dirumuskan seperti pada persamaan 12 (Nasution & Prasetyawan, 2008).

$$MAD = \frac{\sum |x_i - \bar{x}|}{n} \quad (10)$$

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (11)$$

$$MSD = \frac{\sum_{i=0}^n (x_i - \bar{x})^2}{n} \quad (12)$$

3. HASIL DAN PEMBAHASAN

3.1. Pengumpulan Data

Tahap 3 pengumpulan data, sumber data pada penelitian ini berasal dari data transaksi penjualan pada periode 1 Januari 2016 – 31 Desember 2017. Terdapat dua pembagian data pada penelitian ini yaitu periode data 1 Januari 2017 – 31 Desember 2017 digunakan untuk perhitungan dengan algoritma *FP-Growth* sedangkan periode data 1 Januari 2016 – 31 Desember 2017 digunakan untuk perhitungan dengan algoritma *Triple Exponential smoothing*. Data tersebut akan diproses guna menghasilkan pengetahuan yang dapat digunakan untuk pengembangan strategi bisnis. Data yang diperoleh adalah data transaksi meliputi tabel transaksi, tabel barang, dan tabel detail transaksi. Data yang diperoleh berjumlah 72.645 transaksi dan 11.164 barang.

Tabel 1 adalah tabel barang dari *database*. Data pada tabel 1 harus diproses. Karena ada data yang tidak benar maka perlu dilakukan proses *cleaning*.

No	Id	Nama	Harga Beli	Harga Jual	Satuan
1	9447	1	1	2	PCS
2	5369	A	100	200	PCS
3	399	ABC	4.841	6000	PCS
.	.	250	.	.	.
.	.	APL	.	.	.
11.164	11164	SA LIPS	16000	20000	PCS

3.2. Proses Data Mining

Tahap 3 adalah proses *data mining* dimulai dengan tahap *data cleaning* yaitu melakukan validasi data yang kosong maupun *outlier* menjadi data yang valid. Data yang digunakan dalam penelitian ini memiliki beberapa *record* yang tidak sesuai/ salah ketik. Data yang tidak konsisten tersebut diubah/ dilengkapi agar menjadi data yang konsisten.

Tabel 2 adalah tabel barang setelah dilakukan proses *cleaning*. Pada proses ini dilakukan penghapusan data barang yang sudah tidak dipakai.

No	Id	Nama	Harga Beli	Harga Jual	Satuan
1	399	ABC	250	4.841	6000
2	400	APL	250	4841	6000
.	.	ABC	.	.	.
.	.	JMB.	.	.	.
11.162	11164	SA LIPS	16000	20000	PCS

Tahap selanjutnya adalah *data integration* atau proses penggabungan data dari beberapa sumber yang menunjang, namun karena sumber data yang digunakan hanya dari satu *database*, maka tahap ini tidak dilakukan. Kemudian dilakukan proses seleksi data, proses ini dilakukan untuk memilah data yang digunakan dan tidak digunakan. Setelah dilakukan proses seleksi ini, jumlah data yang digunakan berjumlah 40.940 transaksi dan 3.331 barang. Sejumlah 3.331 barang ini dikategorikan menjadi 25 kategori, 25 kategori tersebut dapat dilihat di tabel 3.

Tabel 3 adalah tabel kategori barang yang akan diteliti beserta jumlah barang yang terdapat dalam kategori tersebut. Kategori susu siap minum memiliki 134 barang. Kategori susu bubuk memiliki 345 barang. Kategori teh siap minum terdapat 98 barang. Kategori teh memiliki 58 barang. Kategori kopi siap minum memiliki 32 barang. Kategori kopi memiliki 77 barang. Kategori soda memiliki 27 barang. Kategori air mineral memiliki 55 barang. Kategori suplemen dan vitamin memiliki 103 barang. Kategori minuman serbuk memiliki 55 barang. Kategori minuman ringan memiliki 137 barang. Kategori adu memiliki 34 barang. Kategori sirup memiliki 15 barang. Kategori mie memiliki 119 barang. Kategori roti memiliki 256 barang. Kategori makanan ringan memiliki 964 barang. Kategori kecap memiliki 37 barang. Kategori saos dan sambal memiliki 42 barang. Kategori bumbu dapur memiliki 78 barang. Kategori tepung memiliki 11 barang. Kategori minyak memiliki 32 barang. Kategori gula memiliki 11 barang. Kategori beras memiliki 5 barang. Kategori obat memiliki 371 barang. Kategori permen memiliki 235 barang.

No	Kategori Barang	Jumlah Barang
1	Susu Siap Minum	134
2	Susu Bubuk	345
3	Teh Siap Minum	98
4	Teh	58
5	Kopi Siap Minum	32
6	Kopi	77
7	Soda	27
8	Air mineral	55
9	Suplement & Vitamin	103
10	Minuman Serbuk	55
11	Minuman Ringan	137
12	Madu	34
13	Sirup	15
14	Mie	119
15	Roti	256
16	Snack	964
17	Kecap	37
18	Saos & Sambal	42
19	Bumbu Dapur	78

No	Kategori Barang	Jumlah Barang
20	Tepung	11
21	Minyak	32
22	Gula	11
23	Beras	5
24	Obat	371
25	Permen	235

Dalam data transaksi terdapat 40.940 transaksi, data transaksi tersebut tidak digunakan seluruhnya. Data yang digunakan untuk penelitian berjumlah 10.000 transaksi dan diambil secara acak.

Berikutnya dilakukan *data transformation*, pada tahap ini dilakukan proses pengubahan data transaksi kedalam bentuk data tabular. Pengubahan data ini digunakan untuk pemrosesan data dengan algoritma *FP-Growth*, untuk metode prediksi data diubah kedalam bentuk data berkala. Data yang digunakan untuk pemrosesan dengan algoritma *triple exponential smoothing* dapat dilihat pada tabel 4 dan data yang akan digunakan untuk pemrosesan dengan algoritma *FP-Growth* dapat dilihat pada tabel 5.

Tabel 4. Data Penjualan Gula

No	Bulan	Tahun	Total (Kg)
1	Januari	2016	122
2	Februari	2016	131
3	Maret	2016	313.5
.	.	.	.
24	Desember	2017	234.5

Pengubahan data transaksi kedalam bentuk tabular ini dilakukan dengan cara no/ id transaksi dari data yang akan diuji disusun secara horizontal ke bawah dan semua item/ barang yang akan menjadi atribut berbentuk vertikal, sehingga membentuk sebuah tabel dengan data real transaksi dengan nilai biner 0 dan 1, 1 disini berarti barang tersebut dibeli dan 0 barang tersebut tidak dibeli. Hasil proses konversi data transaksi ke format tabular dapat dilihat pada tabel 5.

Tabel 5 adalah data transaksi dalam bentuk data tabular. Data tersebut merupakan data transaksi. Angka 0 pada atribut kategori barang berarti bahwa dia tidak membeli sedangkan 1 pada atribut tersebut berarti membeli.

Tabel 5. Format Tabular Data Penjualan

No	Id Transaksi	Teh	Kopi	.	.	.	Gula
1	21712255	0	0	.	.	.	1
2	21706230	1	1	.	.	.	1
3	21705325	0	0	.	.	.	1
.
4094	41703204	1	0	.	.	.	0

3.3. FP-Growth

Pada tahap ini dilakukan perhitungan menggunakan software RapidMiner. Algoritma *FP-Growth* membutuhkan dua variabel yang digunakan sebagai standar minimum, dua variabel tersebut adalah *support* dan *confidence*. Pada penelitian ini

penentuan 2 variabel tersebut dilakukan secara *trial and error*. Untuk filter pertama pada metode ini adalah nilai *support*, oleh karena itu langkah pertama sebelum melakukan kombinasi dari nilai *support* dan nilai *confidence* perlu dilakukan pencarian nilai *support* dari tiap kategori. Nilai *support* dari satu kategori (1 item) dapat dilihat pada tabel 6. Tabel 6 menunjukkan nilai *support* dari tiap item/kategori, nilai yang ada pada tabel 5 digunakan untuk acuan dalam percobaan kombinasi nilai *support* dan *confidence*.

Tabel 6. Support 1 Itemset

No	Nama Barang	Support
1	Snack	66,33
2	Permen	27,77
3	Susu_Siap_Minum	27,34
4	Minuman_Ringan	23,09
5	Air_Mineral	18,85
6	Susu_Bubuk	15,99
7	Roti	15,98
8	Gula	12,02
9	Obat	11,97
10	Teh_Siap_Minum	11,64
11	Suplement_Vitamin	10,77
12	Mie	9,85
13	Teh	9,54
14	Kopi_Saset	5,39
15	Soda	4,14
16	Minyak	4,13
17	Sirup	3,02
18	Saos_Sambal	1,87
19	Minuman_Serbuk	1,72
20	Kecap	1,59
21	Bumbu_Dapur	1,41
22	Kopi_Siap_Minum	1,09
23	Madu	0,62
24	Tepung	0,53
25	Beras	0,44

Percobaan pertama dilakukan dengan nilai *support* 25 % dan nilai *confidence* 70%, percobaan pertama menghasilkan aturan asosiasi yang ditunjukkan pada tabel 7. Pada percobaan pertama dengan nilai *support* 25% dan *confidence* 70% yang dapat dilihat dari tabel 7 menunjukkan bahwa aturan asosiasi belum dapat terbentuk. Aturan asosiasi belum dapat terbentuk dikarenakan nilai *support* yang terlalu tinggi.

Tabel 7. Percobaan dengan support 25% dan confidence 70%.

Size	Support	Item 1
1	0.663	Snack
2	0.278	Permen
3	0.273	Susu_Siap_Minum

Percobaan kedua menggunakan nilai *support* 15 % dan *confidence* 70%, percobaan kedua menghasilkan aturan asosiasi yang dapat dilihat pada tabel 8. Pada percobaan kedua dengan nilai *support* 15% dan *confidence* 70% menghasilkan dua aturan asosiasi seperti yang ditunjukkan pada tabel 8. Dua aturan asosiasi tersebut memiliki nilai *support* dan *confidence* diatas dari ketentuan. Pembacaan aturan asosiasi yang pertama adalah jika membeli susu siap minum maka membeli snack, aturan tersebut memiliki *support* 0,200 yang berarti

memiliki 200 transaksi yang mengandung kedua item tersebut dari keseluruhan total transaksi dan *confidence* 0.730 yang berarti nilai dari kekuatan aturan asosiasi tersebut adalah 73% sedangkan *Lift* 1.101 adalah nilai kekuatan aturan asosiasi sama dengan nilai *confidence* namun lebih *independent*.

Tabel 8. Percobaan dengan *support* 15% dan *confidence* 70%

No	Premises	Conclusion	Support	Confidence	Lift
1	Susu Siap Minum	Snack	0.200	0.730	1.101
2	Permen	Snack	0.216	0.777	1.171

Percobaan ketiga menggunakan nilai *support* 10% dan nilai *confidence* 30%, percobaan ketiga menghasilkan aturan asosiasi yang dapat dilihat pada tabel 9. Pada percobaan ketiga dengan nilai *support* 10% dan *confidence* 30% menghasilkan 7 aturan asosiasi seperti yang ditunjukkan pada tabel 9.

Tabel 9. Percobaan dengan *support* 10% dan *confidence* 30%

No	Premises	Conclusion	Support	Confidence	Lift
1	Snack	Susu Siap Minum	0.200	0.301	1.101
2	Snack	Permen	0.216	0.325	1.171
3	Minuman Ringan	Snack	0.120	0.519	0.782
4	Air Mineral	Snack	0.114	0.603	0.909
5	Susu Siap Minum	Snack	0.200	0.730	1.101
6	Roti	Snack	0.120	0.752	1.134
7	Permen	Snack	0.216	0.777	1.171

Percobaan keempat menggunakan nilai *support* 5% dan *confidence* 50%, percobaan ketiga menghasilkan aturan asosiasi yang dapat dilihat pada tabel 10. Percobaan keempat dengan nilai *support* 5% dan *confidence* 50% menghasilkan 12 aturan asosiasi seperti yang ditunjukkan pada tabel 10.

Tabel 10. Percobaan dengan *support* 5% dan *confidence* 50%.


No	Premises	Conclusion	Support	Confidence	Lift
1	Minuman Ringan	Snack	0.120	0.519	0.782
2	Obat	Snack	0.062	0.520	0.783
3	Mie	Snack	0.056	0.571	0.860
4	Teh Siap Minum	Snack	0.067	0.575	0.866
5	Gula	Teh	0.070	0.585	6.131
6	Susu Bubuk	Snack	0.095	0.592	0.892
7	Air Mineral	Snack	0.114	0.603	0.909
8	Susu Siap Minum	Snack	0.200	0.730	1.101
9	Teh	Gula	0.070	0.737	6.131
10	Roti	Snack	0.120	0.752	1.134
11	Permen, Susu Siap Minum	Snack	0.069	0.767	1.156
12	Permen	Snack	0.216	0.777	1.171

Hasil dari percobaan pertama sampai keempat membuktikan bahwa semakin kecil nilai *support* dan semakin kecil nilai *confidence* semakin banyak aturan asosiasi yang terbentuk, namun aturan tersebut belum tentu semuanya berguna. Dari hasil percobaan pertama sampai keempat dipilih

percobaan keempat sebagai aturan asosiasi yang di pakai untuk penyusunan tata letak barang. Pemilihan aturan asosiasi ini dikarenakan pada percobaan pertama belum terdapat aturan asosiasi yang terbentuk, pada percobaan kedua aturan yang terbentuk masih kurang untuk menyusun skema tata letak barang begitu juga percobaan ketiga, percobaan keempat dinilai cukup untuk mendapatkan skema tata letak barang.

3.4. Perancangan *Layout*

Perancangan *layout* adalah tahapan setelah ditemukan hubungan antar *item* (aturan asosiasi). Perancangan/ penataan disini dengan cara menaruh barang aturan asosiasi yang memiliki nilai *lift* tinggi di belakang dengan tujuan meningkatkan pembelian untuk barang yang memiliki *support* rendah. Gambar 2 adalah gambar *layout* di tempat penelitian.



Gambar 2. *Layout* Rak barang di bagian kebutuhan sehari hari

Gambar 2 adalah *layout* penataan rak barang di bagian kebutuhan sehari hari. Terdapat 1 etalase dengan bertingkat dengan kode A, 2 rak dengan 4 tingkat berkode B dan C dan ada 1 rak 3 tingkat dengan kode D. Penataan barang sebelum dilakukan penelitian ini dapat dilihat pada tabel 11.

Tabel 11 adalah tabel yang menunjukkan lokasi rak dari setiap kategori barang. Penataan cenderung tidak beraturan/ tanpa melihat kombinasi dari aturan asosiasi. Penataan yang sesuai dengan aturan asosiasi yang sudah terbentuk dapat dilihat pada tabel 12.

Tabel 11. Penataan barang sebelum diteliti

Nomor Rak	Nama Barang
B3.1, B3.2, B4.1, B4.2, C3.1, C4.1, C4.2	Snack
B1.4	Permen
B1.1	Susu_Siap_Minum
B2.1	Minuman_Ringan
C1.3	Air_Mineral
D3.2, D3.3, D4.2, D4.3	Susu_Bubuk
C4.3, C4.4	Roti
B1.2, B1.3	Gula
A2.1	Obat
C2.1	Teh_Siap_Minum
A1.1	Suplement_Vitamin
B4.3, B4.4	Mie
C1.4	Teh
C2.2, C3.2	Kopi_Saset
C1.2	Soda
B2.2, B2.3	Minyak
D1.1, D1.2	Sirup
B2.4	Saos_Sambal
C2.3, C3.3	Minuman_Serbuk
B3.4	Kecap
D2.1	Bumbu_Dapur
C1.1	Kopi_Siap_Minum
C2.4, C3.4	Madu
D2.2	Tepung
D1.3	Beras

Tabel 12 adalah tabel penataan barang setelah diteliti dengan mengaitkan keterkaitan hubungan asosiasi yang dihasilkan dari algoritma FP-Growth. Tata letak yang baru ini diharapkan dapat meningkatkan penjualan kategori barang yang memiliki support kecil.

Tabel 12. Penataan barang setelah diteliti

Nomor Rak	Nama Barang
C3.1, C3.2, C3.3, C4.1, C4.2, C4.3, C4.4	Snack
C3.4	Permen
C1.4	Susu_Siap_Minum
C1.2	Minuman_Ringan
C1.3	Air_Mineral
B1.3, B2.3, B3.3, B3.4	Susu_Bubuk
C2.4, C2.3	Roti
D1.2, D1.3	Gula
A2.1	Obat
C1.1	Teh_Siap_Minum
A1.1	Suplement_Vitamin
D3.1, D3.2, D3.3	Mie
D2.3	Teh
B2.2, B2.3	Kopi_Saset
C2.2	Soda
D2.1, D2.2	Minyak
B1.1, B1.2	Sirup
B4.4	Saos_Sambal
B2.1, B3.1	Minuman_Serbuk
B3.4	Kecap
B1.4	Bumbu_Dapur
B3.2, B2.2	Kopi_Siap_Minum
B4.1, B4.2	Madu
B2.4	Tepung
D1.1	Beras

3.5. Exponential Smoothing

Algoritma *Triple Exponential Smoothing* terdapat nilai musim. Data yang digunakan adalah data transaksi gula dari Januari 2016 – Desember 2017. Untuk perhitungan menggunakan metode *Triple Exponential Smoothing* diperlukan satu

variabel α, β, γ . Penentuan variabel α, β, γ dapat ditentukan secara bebas/ acak, variabel ini memengaruhi hasil perhitungan prediksi yang nantinya dapat diuji dengan beberapa metode pengujian (MSE, MAD, MAPE).

Algoritma 1 adalah proses prediksi dengan metode *Triple Exponential Smoothing*, proses pertama dilakukan untuk melakukan proses inisiasi peramalan dengan ketentuan bahwa untuk $S'_0 = X_0$ dan $S''_0 = X_0$ pada baris 7, apabila nilai $i = 1$ untuk setiap data selanjutnya $S'_t = \alpha X_t + (1 - \alpha) S'_{t-1}$ dan $S''_t = \alpha S'_t + (1 - \alpha) S''_{t-1}$ maka ditentukan nilai $\alpha_t = 2S'_t - S''_t$ dan nilai $b_t = \frac{\alpha}{1-\alpha} (S'_t - S''_t)$ pada baris 14. Proses prediksi dimulai dari indeks data ketiga pada baris 19 karena dalam mencari nilai prediksi pada indeks pertama memerlukan nilai α_t dan b_t , sedangkan nilai α_t dan b_t belum dapat ditentukan. Demikian pula proses berikutnya pada indeks data kedua untuk mencari nilai prediksi diperlukan nilai α_t dan b_t dari indeks sebelumnya, demikian seterusnya. Formula yang digunakan untuk menentukan nilai prediksi adalah $F_{t+m} = \alpha_t + b_t m$.


```

Input : data[N] ← data penjualan sebanyak N
1. single[N] ← pemulusan 1 sebanyak N
2. alpha[N] ← alpha pemulusan sebanyak N
3. beta[N] ← beta pemulusan sebanyak N
4. hasil[N] ← prediksi penjualan sebanyak N
5. α ← parameter pemulusan
6. alpha ← 0.1/0.2
7. If i = 1 then
8.   single[i] ← data[i]
9.   double[i] ← data[i]
10.  alpha[i] ← 0
11.  double[i] ← 0
12. Else then
13.   For i = 1 to N do
14.    single[i] ← α * data[i] + (1 - α) * single[i - 1]
15.    double[i] ← α * single[i] + (1 - α) * double[i - 1]
16.    alpha[i] ← 2 * single[i] + double[i]
17.    beta[i] ←  $\frac{\alpha}{1 - \alpha} * (single[i] - double[i])$ 
18.   End If
19.   If i > 2 then
20.    hasil[i] ← alpha[i - 1] + beta[i - 1]
21.   Else then
22.    hasil[i] ← 0
23.   End If
24.   End For

```

Algoritma 1. Prediksi *exponential smoothing*

Sebelum melakukan pengujian menggunakan algoritma *Triple Exponential Smoothing* perlu dilakukan pembacaan pola. Pola pada data penjualan gula dari Januari 2016 – Desember 2017 dapat dilihat pada gambar 3.



Gambar 3. Plot Data Penjualan Gula Periode Januari 2016 – Desember 2017


Gambar 3 adalah plot data penjualan gula periode Januari 2016 – Desember 2017. Rentang *horizontal* menunjukkan rentang waktu sedangkan rentang *vertikal* merupakan jumlah penjualan gula. Gambar 3 menunjukkan data yang tidak stasioner, data yang tidak memiliki rata-rata yang tetap dan cenderung memiliki *trend* naik. Terdapat lonjakan data yang sangat signifikan, lonjakan data tersebut dipengaruhi dari musim, sehingga data penjualan gula ini memiliki pengaruh musim. Pengujian ini menggunakan α, β, γ secara acak. Pengujian ini menggunakan software Minitab. Hasil pengujian dari setiap α ditunjukkan oleh tabel 13.

Tabel 13 adalah tabel hasil pengujian menggunakan 3 metode yaitu MAPE, MSD dan MAD. Angka hasil pengujian menunjukkan tingkat galat (*error*) antara data *training* dengan model prediksi. Hasil dari 15 kali percobaan menghasilkan model terbaik dengan nilai $\alpha = 0,3$, $\beta=0,01$, $\gamma=0,01$. Hasil pengujian terbaik menggunakan metode MAPE dengan nilai kesalahan 11,7 % atau dengan akurasi prediksi 88,3 %. Grafik model dengan nilai $\alpha = 0,3$, $\beta=0,01$, $\gamma=0,01$ dapat dilihat pada gambar 4. Tabel 14 adalah hasil pengujian menggunakan metode *Triple Exponential Smoothing* dengan hasil pengujian pada Januari 2018 adalah 131,141 kg.

Gambar 4 adalah gambar hasil dari perhitungan menggunakan *triple exponential smoothing* dengan $\alpha = 0,3$, $\beta=0,01$, $\gamma=0,01$, hasil prediksi pada periode berikutnya adalah 131,1 kg. Hasil dari prediksi menggunakan metode ini dapat dilihat pada tabel 14.

Tabel 13. Hasil Pengujian

No	α	β	γ	MAPE	MAD	MSD
1	0,1	0,1	0,1	34,9	127,4	53533,8
2	0,1	0,5	0,9	41,7	150,5	88069,4
3	0,1	0,3	0,2	34,7	127,8	56558,1
4	0,1	0,05	0,2	35,8	130,5	56391,7
5	0,4	0,5	0,2	41,7	137,3	70447,9
6	0,2	0,2	0,2	33,7	124,6	57427,9
7	0,3	0,2	0,5	39,5	139,2	76006,7
8	0,2	0,2	0,5	37	135,3	70453,2
9	0,2	0,4	0,6	42	145,4	80152,7
10	0,4	0,2	0,2	36,6	128,7	64228,2
11	0,9	0,05	137,3	39,6	137,3	74960,3
12	0,5	0,05	0,01	33,4	122,2	57971
13	0,2	0,05	0,01	33,3	122,1	50873,8
14	0,01	0,05	0,01	36,5	130,8	53140
15	0,3	0,01	0,01	11,7	121,3	52056,5



Gambar 4. Grafik Prediksi Pengujian Gula Periode Januari 2016 – Desember 2017

Tabel 14. Hasil Pengujian dengan $\alpha = 0,3$, $\beta=0,01$, $\gamma=0,01$

No	Periode	Aktual	Prediksi
1	Januari 2016	122,0	131,56
2	Februari 2016	131,0	129,75
3	Maret 2016	313,5	276,72
4	April 2016	330,5	286,54
5	Mei 2016	353,5	343,24
6	Juni 2016	528,0	1025,40
7	Juli 2016	1143,0	604,79
8	Agustus 2016	101,5	175,99
9	September 2016	113,0	190,87
10	Oktober 2016	117,0	133,34
11	November 2016	104,5	96,26
12	Desember 2016	118,5	120,58
13	Januari 2017	105,5	73,46
14	Februari 2017	105,5	82,38
15	Maret 2017	205,5	187,49
16	April 2017	202,5	189,26
17	Mei 2017	275,5	217,42
18	Juni 2017	1393,0	682,77
19	Juli 2017	234,0	627,48
20	Agustus 2017	224,5	114,31
21	September 2017	307,0	183,60
22	Oktober 2017	232,5	179,12
23	November 2017	170,5	150,02
24	Desember 2017	234,5	195,56
25	Januari 2018		131,141

4. Kesimpulan

4.1. Kesimpulan

Berdasarkan hasil pengujian dengan kombinasi algoritma *FP-Growth* dan *Triple Exponential Smoothing* terhadap data transaksi penjualan, dapat disimpulkan bahwa hasil pengujian menggunakan RapidMiner telah terbukti dapat menerapkan algoritma *FP-Growth* untuk mendapatkan pola belanja konsumen. Ditemukan 12 aturan asosiasi dengan aturan asosiasi yang memiliki nilai *lift ratio* paling tinggi adalah teh dan gula dengan nilai *lift ratio* 6.131 Riset memiliki kontribusi meningkatkan akurasi prediksi dibanding riset sebelumnya, hasil pengujian menggunakan Minitab telah terbukti dapat menerapkan algoritma *Triple Exponential Smoothing* dengan baik, dan memberikan nilai prediksi pada bulan Januari 2018 adalah 131,141 Kg dengan nilai pengujian error MAPE=11,7 (akurasi MAPE 88.3%), MSD=121,3 dan MAD = 52056,5 dengan besaran nilai $\alpha = 0,3$, $\beta=0,01$, $\gamma=0,01$.

Hasil akurasi prediksi stok dengan metode *Triple Exponential Smoothing* lebih baik dibandingkan prediksi menggunakan metode

ARIMA, nilai pengujian *error* MAPE prediksi dengan metode ARIMA adalah sebesar 31,68 % (akurasi MAPE 68,32 %). Hasil riset menunjukkan adanya rekomendasi optimalisasi tata letak barang untuk dapat meningkatkan penjualan barang ke depan. Hasil riset juga merekomendasi optimalisasi stok barang berdasarkan prediksi stok untuk efisiensi persediaan barang di gudang.

4.2. Saran

Penelitian selanjutnya disarankan menggunakan data jumlah transaksi yang lebih banyak (diatas 10.000 transaksi), penggunaan data lebih banyak dapat meningkatkan akurasi dari aturan asosiasi, cakupan kategori barang lebih luas dan periode data yang digunakan untuk melakukan prediksi lebih lama. Model yang dihasilkan masih bisa ditingkatkan akurasinya dengan menambahkan jumlah periode data *history*.

DAFTAR PUSTAKA

- AGUNG, M, T. & NURHADIYONO, B., 2015. Penerapan Data Mining Pada Data Transaksi Penjualan Untuk Mengatur Penempatan Barang Menggunakan Algoritma Apriori, [online] Tersedia di: <http://eprints.dinus.ac.id/16908/2/abstrak_16085.pdf> [Diakses 3 Februari 2018]
- BILQISTH, S, C., 2016. Analisis Pola Pembelian Konsumen Dengan Algoritma Apriori Pada Indomaret Indraprasta Semarang, [online] Tersedia di: <http://eprints.dinus.ac.id/18197/1/abstrak_17714.pdf> [Diakses 3 Februari 2018]
- DARMAWAN, D. R. et al., 2018. Analisis Peramalan Penjualan dengan Menggunakan Metode Single Moving Average, Weighted Moving Average dan Exponential Smoothing sebagai Dasar Perencanaan Produksi Polo Shirt Pria (Studi Kasus Pada PT. Amanah Garment Bandung).
- FITRIA, V, A. & HARTONO, R., 2017. Peramalan Jumlah Penumpang Pada Siluet Tour And Travel Kota Malang Menggunakan Metode Triple Exponential Smoothing. *Jurnal Ilmiah Teknologi Informasi Asia*, V.11, n.1, p.15-20.
- HARTOMO, K. D., & WINARKO, E., 2015. Winters Exponential Smoothing And Z-Score, Algorithms For Prediction Of Rainfall. *Journal of Theoretical & Applied Information Technology*, 73(1).
- HIDAYAH, L., 2015. Rancang Bangun Sistem Informasi Manajemen Persediaan Barang Dengan Menggunakan Metode Exponential Smoothing Di B-MART Swalayan Jombang, [online] Tersedia di : <<http://eprints.unipdu.ac.id/44/>> [Diakses 3 Februari 2018]
- IKHSANA, Y. et al., 2015. Implementasi Data Mining Dengan Menggunakan Algoritma FP-Growth Untuk Menentukan Pola Penjualan Barang Pada Event Tertentu (Studi Kasus: Berkah Swalayan). *Jurnal Aksara Komputer Terapan*, V.4, N.2.
- MAKRIDAKIS, S. Et al., 1999. Metode Dan Aplikasi Peramalan, Edisi Kedua. Jakarta : Binarupa Aksara.
- NASUTION, A.H. & PRASETYAWAN, Y., 2008. Perencanaan dan Pengendalian Produksi. Yogyakarta : Graha Ilmu.
- SANTOSO, S., 2009. Business forecasting metode peramalan bisnis masa kini dengan minitab dan SPSS. Yogyakarta : Elex Media Komputindo.
- TAMARA, P, W., 2016. Penentuan Desain Tata Letak Penataan Produk Berdasarkan Market Basket Analysis Dengan Menggunakan Algoritma Apriori di Minimarket Alfamart Patimura Ungaran, [online] Tersedia di : <http://eprints.dinus.ac.id/19859/1/abstrak_18548.pdf> [Diakses 3 Februari 2018]
- TARIGAN, T. C. Et al., 2017. Penerapan Algoritma Apriori dan FP-Growth untuk Mengenali Pola Pembelian Pelanggan pada Elmart Swalayan. *Jurnal Aksara Komputer Terapan*, v5(2). Tersedia di : <<https://jurnal.pcr.ac.id/index.php/jakt/article/view/775>> [Diakses 3 Februari 2018]
- TRATAR, L. F. et al., 2016. Demand forecasting with four-parameter exponential smoothing. *International Journal of Production Economics*, 181, 162-173.
- UTAMI, R. & ATMOJO, S., 2017a. Perbandingan Metode Holt Exponential Smoothing dan Winter Exponential Smoothing Untuk Peramalan Penjualan Souvenir. *Jurnal Ilmiah Teknologi Informasi Asia*, V.11, n.2, p.123-130.
- UTAMI, R. & ATMOJO, S., 2017b. Implementasi Metode Triple Exponential Smoothing Additive Untuk Prediksi Penjualan Alat Tulis Kantor (ATK) Pada "X Stationery". *Jurnal Publikasi Dosen*, [Online] Tersedia di <<http://jurnal.itats.ac.id/wp-content/uploads/2017/12/sntekpan-ruli.pdf>> [Diakses 3 Februari 2018]
- WU, L. et al., 2016. Grey double exponential smoothing model and its application on pig price forecasting in China. *Applied Soft Computing*, 39, 117-123.