

**TEKNIK DATA MINING UNTUK PENENTUAN PAKET HEMAT SEMBAKO DAN
KEBUTUHAN HARIAN DENGAN MENGGUNAKAN ALGORITMA FP-GROWTH
(STUDI KASUS DI ULFAMART LUBUK ALUNG)**

Amelia Nastuti¹⁾

Universitas Putra Indonesia YPTK Padang
Email: amelianas2310@gmail.com

Syaiful Zuhri Harahap²⁾

Fakultas Sains dan Teknologi, Universitas Labuhanbatu
Email: syaifulzuhriharahap@gmail.com

Abstrak

Dalam sebuah bisnis, diperlukan upaya memaksimalkan keuntungan. Diantaranya dengan melakukan promosi. Minimarket Ulfamart belum melakukan inovasi berupa promosi paket hemat kepada pelanggan. Ketepatan promosi dapat dipelajari dari database sebuah perusahaan ritel utamanya pola belanja pada produk yang biasa dibeli bersamaan. Informasi tentang pola belanja pelanggan yang tidak akurat menyebabkan kebijakan promosi tidak tepat dan efisien. Salah satu upaya lazim untuk memperoleh dan menggali pola belanja pelanggan adalah menggunakan data mining yang dikenal sebagai Knowledge Discovery in Database (KDD). Salah satu teknik data mining adalah Association Rule yang merupakan prosedur dalam Market Basket Analysis. Market basket didefinisikan sebagai suatu itemset yang dibeli secara bersamaan oleh pelanggan dalam suatu transaksi. Market basket analysis adalah suatu alat yang ampuh untuk strategi cross-selling. Suatu pola ditentukan oleh dua parameter, yaitu support (nilai penunjang) dan confidence (nilai kepastian). Algoritma Frequent Pattern Growth (FP-Growth) digunakan untuk membantu menemukan sejumlah aturan asosiasi dari basis data dengan menerapkan struktur data Tree atau disebut dengan FP-Tree. Implementasi menggunakan RapidMiner untuk membantu menemukan pola yang akurat sehingga didapatkan kombinasi item yang dapat dijadikan sebuah paket hemat.

Kata kunci : data mining, aturan asosiasi, fp-growth, fp-tree, analisis keranjang belanja

Abstract

In a business, it takes effort to maximize profits. Among them by doing promotions. Minimarket Ulfamart has not done innovation in the form of promotion of frugal packages to customers. The precision of promotion can be learned from the database of a retail company primarily shopping patterns on products commonly purchased simultaneously. Information about inaccurate customer spending patterns results in inaccurate and efficient promotional policies. One of the most common attempts to acquire and explore customer spending patterns is to use data mining known as Knowledge Discovery in Database (KDD). One of the data mining techniques is the Association Rule which is a procedure in Market Basket Analysis. Market basket is defined as an itemset purchased simultaneously by the customer in a transaction. Market basket analysis is a powerful tool for cross-selling strategies. A pattern is determined by two parameters, namely support (value of support) and confidence (value of certainty). The Frequent Pattern Growth (FP-Growth) algorithm is used to help find some association rules from the database by applying a Tree structure or called FP-Tree. Implementation using RapidMiner to help find accurate patterns to get a combination of items that can be used as a frugal package.

Keywords: data mining, association rule mining, fp-growth, fp-tree, market basket analysis.

I. PENDAHULUAN

Pertumbuhan kegiatan jual-beli di Indonesia tercermin dengan pesatnya pertumbuhan minimarket sebagai salah satu pasar modern dan pasokan baru di Indonesia. Bisnis minimarket saat ini mengalami perkembangan pesat apalagi dengan menggunakan sistem yang lebih modern memudahkan dalam penghitungan sehingga dapat mengimbangi kebutuhan masyarakat yang tinggi. Minimarket menawarkan konsep *recreational shopping* atau wisata belanja yang tidak jauh dari rumah sehingga pembeli tidak perlu repot jauh - jauh untuk berbelanja. Studi kasus yang diangkat pada penelitian ini adalah minimarket Ulfamart yang beralamat di Jl. Padang – Bukittinggi KM 37, Lubuk Alung. Minimarket ini menjual berbagai macam kebutuhan layaknya toko *retail* pada umumnya, termasuk kebutuhan sembako. Pembeli yang rata-rata ibu rumah tangga ingin membeli beberapa sembako sekaligus kebutuhan harian dengan harga yang murah. Minimarket Ulfamart belum pernah mengeluarkan atau menjualkan produk dalam bentuk paket hemat.

Salah satu cara yang dapat diterapkan untuk menggali informasi adalah dengan menerapkan penggunaan *Data Mining*. *Data mining* adalah suatu proses menemukan hubungan yang berarti, pola, dan kecenderungan dengan memeriksa dalam sekumpulan besar data yang tersimpan dalam penyimpanan dengan menggunakan teknik pengenalan pola seperti teknik statistik dan matematika [1]. *Association rule mining* merupakan cara terbaik untuk memberikan dukungan keputusan ilmiah pada pasar *retail* melalui hubungan *mining association* antara barang yang telah dibeli secara bersama-sama. Penemuan dari hubungan ini dapat membantu pedagang untuk mengembangkan strategi penjualan dengan mempertimbangkan barang yang sering dibeli bersama oleh pelanggan, hal ini sangat penting karena dapat membantu rekomendasi produk yang dapat

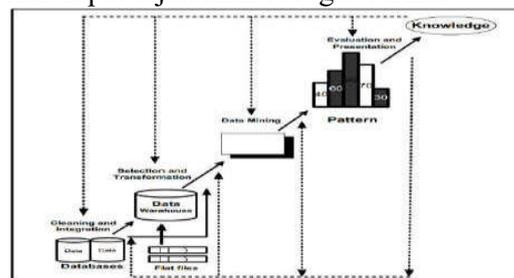
dikombinasikan menjadi sebuah paket. Banyak algoritma yang diusulkan untuk menemukan pola asosiasi. Adapun dalam penelitian ini akan dibahas bagaimana cara mengimplementasikan salah satu algoritma dalam *Data Mining*, yaitu algoritma *frequent Pattern-Growth (FP-Growth)*. Algoritma ini memampatkan kumpulan data sebuah *FP-tree*, memindai database dua kali, tidak menghasilkan *item* kandidat dalam proses penambangan, dan sangat efisien untuk penambangan [2].

Penelitian tentang penerapan aturan asosiasi menggunakan Algoritma *FP-Growth* telah dilakukan oleh Goldie & Dana (2012) membahas tentang market basket analysis terhadap data penjualan produk buku dengan algoritma apriori dan *FP-Growth*, penelitian lain oleh Fitriyani (2015) mengimplementasikan algoritma *fp-growth* menggunakan *association rule* pada market basket analysis, Ghazali dkk (2017) menganalisa pola belanja dengan algoritma *FP-Growth*. Penelitian kali ini diharapkan memberikan nilai lebih berupa kemudahan bagi pengelola minimarket dalam menentukan produk yang dapat digabungkan menjadi sebuah paket sebagai bentuk inovasi baru dalam hal promosi.

II. LANDASAN TEORI

Knowledge Discovery in Database (KDD)

Knowledge Discovery in Database melibatkan hasil proses *Data Mining* (proses pengekstrak kecenderungan suatu pola data), kemudian mengubah hasilnya secara akurat menjadi informasi yang mudah dipahami [3]. Proses KDD secara garis besar dapat dijelaskan sebagai berikut :



Gambar 1. Proses Knowledge discovery in database.

Tahapan proses KDD ada 5 (Irwan Budiman, 2012), yaitu:

1) *Data Selection*

Pemilihan data dari sekumpulan data operasional perlu dilakukan sebelum tahap penggalian informasi dalam KDD dimulai.

2) *Preprocessing*

Sebelum proses *data mining* dapat dilaksanakan, perlu dilakukan proses cleaning dengan tujuan untuk membuang duplikasi data, memeriksa data yang inkonsisten, dan memperbaiki kesalahan pada data, seperti kesalahan cetak. Juga dilakukan proses *enrichment*, yaitu proses “memperkaya” data yang sudah ada dengan data atau informasi lain yang relevan dan diperlukan untuk KDD, seperti data atau informasi eksternal.

3) *Transformation*

Yaitu proses *coding* pada data yang telah dipilih, sehingga data tersebut sesuai untuk proses data mining. Proses *coding* dalam KDD merupakan proses kreatif dan dangat tergantung pada jenis atau pola informasi yang akan dicari dalam *database*.

4) *Data Mining*

Proses mencari pola atau informasi menarik dalam data terpilih dengan menggunakan teknik atau metode tertentu.

5) *Interpretation / Evaluation*

Pola informasi yang dihasilkan dari proses *data mining* perlu ditampilkan dalam bentuk yang mudah dimengerti oleh pihak yang berkepentingan. Tahap ini merupakan bagian dari proses KDD yang disebut dengan *interpretation*. Tahap ini mencakup pemeriksaan apakah pola atau informasi yang ditemukan bertentangan dengan fakta atau hipotesa yang ada sebelumnya atau tidak.

Data Mining digunakan untuk

ekstraksi informasi penting yang tersembunyi dari *dataset* yang besar. Dengan adanya *Data Mining* maka akan didapatkan suatu permata berupa pengetahuan di dalam kumpulan data – data yang banyak jumlahnya [5].

III. METODE PENELITIAN

Fp-Growth

Algoritma FP-Growth merupakan pengembangan dari algoritma Apriori. Sehingga kekurangan dari algoritma Apriori diperbaiki oleh algoritma FP-Growth. 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. Pada algoritma Apriori diperlukan generate candidate untuk mendapatkan frequent itemsets. Akan tetapi, di algoritma FP-Growth generate candidate tidak dilakukan karena FP-Growth menggunakan konsep pembangunan tree dalam pencarian frequent itemsets. Hal tersebutlah yang menyebabkan algoritma FP-Growth lebih cepat dari algoritma Apriori [6].

Untuk menentukan *frequent itemset* pada data transaksi tersebut, dapat dilakukan langkah-langkah berikut ini:

1. Menentukan *Minimum Support*.
2. Menentukan *Header Frequent Itemset*
3. Membuat *FP-Tree*
4. Membuat *Conditional Pattern* berdasarkan *FP-Tree*
5. Menentukan *Frequent Item-set*

Penelitian ini melakukan tahapan dari analisa mulai dari data secara keseluruhan serta proses manual pembahasan dari pengolahan data yang akan dilakukan asosiasi menggunakan pemodelan FP-growth berdasarkan kerangka kerja penelitian yang terdapat pada bab III Metodologi Penelitian. Secara garis besar tahapan dari proses analisa dan pembahasan pada bab ini dapat digambarkan dalam bagan alir sebagai berikut:



Gambar 2. Bagan Alir Tahapan Analisa dan Perancangan

HASIL DAN PEMBAHASAN

Data yang digunakan untuk pengolahan data ini adalah data terakhir yang sudah dilakukan proses pembersihan data. Dalam tahap ini akan dilakukan penyelesaian masalah pada rekomendasi paket produk di minimarket Ulfamart dengan metode *Association Rule* menggunakan Algoritma *FP-Growth*.

Berdasarkan tujuan bisnis pada minimarket Ulfamart data yang digunakan dalam penelitian ini adalah laporan transaksi penjualan produk sembako dan kebutuhan harian pada bulan Juni 2017 sampai dengan Agustus 2017 yang berasal dari database file (dbf). Atribut yang terdapat pada laporan transaksi penjualan terdiri dari:

1. Notrans
2. Barcode
3. Waktu
4. Uraian
5. Qty
6. Jumlah
7. Total
8. Bayar
9. Kembalikan

Persiapan data adalah hal yang harus dilakukan, karena tidak semua atribut digunakan dalam proses data mining. Proses ini dilakukan agar data yang akan digunakan sesuai dengan kebutuhan. Adapun tahapan *preprocessing* adalah sebagai berikut:

1. Ekstraksi data

Ekstraksi data adalah proses pengambilan data dari sumber data dalam rangka untuk melanjutkan proses pengolahan data. Dalam penelitian ini data diambil dari file dbf. Data yang digunakan adalah data transaksi penjualan.

2. Pemilihan atribut

Pemilihan atribut adalah proses pemilihan atribut data yang digunakan, sehingga data tersebut dapat diproses sesuai dengan kebutuhan *data mining*. Dalam tahap ini atribut yang digunakan adalah Faktur dan Kode *item*. Faktur merupakan identitas dari setiap transaksi, sedangkan Kode *item* digunakan untuk mengetahui jenis barang apa saja yang dibeli oleh pelanggan.

3. Pembersihan data

Proses menghilangkan *noise* dan menghilangkan data yang tidak relevan disebut pembersihan data. Dari ±1.000 total jumlah transaksi mentah, dilakukan proses *cleaning* data agar didapatkan data yang sesuai dengan kebutuhan penggalian informasi sebanyak 15 transaksi yang merupakan *item* produk sembako dan kebutuhan harian. Sampel transaksi penjualan pada Minimarket Ulfamart disajikan pada tabel 1 berikut.

Tabel 1. Sampel Transaksi Penjual

Transak	Item yang Terjual
TR01	Gula Biasa 1kg, Kopi Mak Angah
TR02	Beras Solok 5kg, Indomie <i>Realmeat Beef</i> ,
TR03	Mila Tepung Terigu 1kg, Gula Biasa
TR04	<i>Okey</i> Sosis Ayam 1.000gram, <i>Kraft Cheddar</i> 180g, Kobe Bumbu Instan 12g Ori
TR05	Beras Solok 5kg, Delima 2ltr
TR06	Bango Kecap Manis 275ml, Kobe Bumbu
TR07	Prendjak Teh Celup 30, Gula Biasa 1kg, Kopi Mak Angah
TR08	<i>Kraft Cheddar</i> 180g, <i>Frisian Flag Krimer</i>
TR09	Abc Sambal Asli Btl275ml, Prendjak Teh
TR10	Prendjak Teh Celup 30, Gula Biasa 1kg
TR11	<i>Frisian Flag Krimer</i> 385gr, Gula Biasa 1kg, Kopi Mak Angah, Prendjak Teh Celup 30
TR12	Mila Tepung Terigu 1kg, Gula Biasa 1kg,
TR13	Mila Tepung Terigu 1kg, Indomie <i>Realmeat Beef</i> , Sirup ABC Squash
TR14	<i>Frisian Flag Krimer</i> 385gr, Prendjak Teh
TR15	Bango Kecap Manis 275ml, <i>Kraft Cheddar</i> 180g

transaksi pada tabel nantinya akan disederhanakan dengan cara menginisialisasi. Setelah *item* yang terjual pada setiap transaksi disederhanakan, selanjutnya adalah membuat transformasi agar lebih sederhana. Bentuk data dalam bentuk format *transactional* berdasarkan pada transaksi-transaksi yang ada pada tabel 1 terlihat pada tabel 2 data *transactional* nya.

Tabel 2. Data Format Transactional

Nama item	Inisial	Transaksi
Beras solok 5kg	A	2
Mila tepung terigu 1kg	B	3
Gula biasa 1kg	C	7
Kopi mak angah kecil	D	3
Prendjak teh celup 30	E	5
Delima 2ltr	F	2
Indomie realmeat beef	G	2
Bango kecap manis 275ml	H	2
ABC sambal asli bt1275ml	I	1
Okey sosis ayam 1.000gram	J	1
Kraft cheddar 180g	K	3
Kobe bumbu instan 12g	L	2
Frisian flag krim 385gr	M	3
Promas Kornek Sapi 200gr	N	0
Sarden ABC mackerel	O	0
Blue band cup	P	2
Aqua gallon	Q	1
Cuka Dapur 150ml	R	0
Okey nugget ayam 1.000gram	S	1
Sirup ABC squash jeruk	T	1

Tahap pemodelan FP-Growth

Pada tahap awal dalam pemodelan adalah menentukan *minimum support*. *Minimum support* adalah suatu ukuran yang menunjukkan seberapa besar tingkat suatu kombinasi suatu barang pada sebuah data transaksi. Untuk kasus nilai *minimum support* yang digunakan yaitu 10% dari 15 data transaksi

penjualan yang digunakan yaitu sebesar 1,5 dibulatkan jadi 2, yang berarti barang yang memiliki jumlah frequent kurang dari 2 akan dieliminasi dalam data transaksi. Langkah pertama yang dilakukan untuk menghitung nilai support dari sebuah barang adalah dengan menghitung kemunculan tiap barang yang sudah disusun secara ascending. Jumlah kemunculan setiap barang dapat dilihat pada Tabel 3.

Tabel 3. Frequent Item

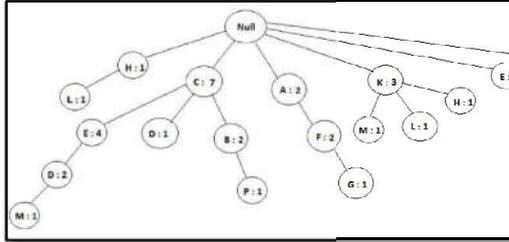
Kode item	Frequent
A	2
B	3
C	7
D	3
E	5
F	2
G	2
H	2
I	1
J	1
K	3
L	2
M	3
N	0
O	0
P	2
Q	1
R	0
S	1
T	1

Setelah mengetahui nilai *frequent* dari semua *item*, langkah selanjutnya adalah mengeliminasi *item* yang tidak memenuhi minimum support yang telah ditentukan. Pada tahap ini *item* yang memiliki frequent tertinggi akan didahulukan penulisannya. Hasil pengurutan berdasarkan priority dapat dilihat pada Tabel 4. Hasil pengurutan berdasarkan priority berikut ini :

Tabel 4. Hasil Pengurutan Berdasarkan

Faktur	Kode-item
TR01	C,D
TR02	A,F,G
TR03	C,B
TR04	K,L
TR05	A,F
TR06	H,L
TR07	C,E,D
TR08	K,M
TR09	C,E
TR10	C,E
TR11	C,E,D,M
TR12	C,B,P
TR13	B,G
TR14	E,M,P
TR15	K,H

Setelah proses pembacaan faktor TR15 yaitu K,H maka terbentuklah Tree dari semua transaksi yang akan digunakan seperti pada Gambar Hasil pembentukan FP-Tree faktor TR15:



Gambar 3.FP-Tree Setelah Pembacaan TR15

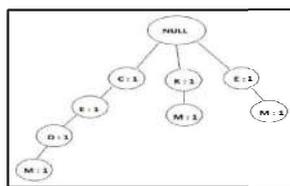
Pembangkitan conditional pattern base didapatkan melalui hasil FP-Tree seluruhnya, dengan mencari support count terkecil sesuai dengan hasil pengurutan priority. Berikut adalah hasil dari conditional pattern base yang terlihat pada tabel 5.

Tabel 5. Conditional Pattern Base

Item	Conditional Pattern Base
P	{C,B:1}{E,M:1}
L	{H:1}{K:1}
H	{K:1}
G	{A,F:1}{B:1}
F	{A:2}
M	{C,E,D:1}{K:1}{E:1}
D	{C,E:2}{C:1}
B	{C:2}
E	{C:4}

Pada tahap ini, support count dari setiap item pada setiap conditional pattern base dijumlahkan, lalu setiap item yang memiliki jumlah support count lebih besar atau sama dengan minimum support akan dibangkitkan dengan Conditional FP-Tree.

Conditional FP-Tree untuk kode produk M {E:2}



Gambar 4. Conditional FP-Tree

Setelah mendapatkan hasil conditionalFp-Tree, ditemukan beberapa frequent itemset yang keluar seperti pada Tabel 6.Conditional FP-Tree:

Tabel 6.Conditional Fp-Tree

Item	Conditional FP-Tree
F	{A:2}
M	{E:2}
D	{C:3}{E:2}
B	{C:2}
E	{C:4}

Setelah mendapatkan hasil Conditional Fp-Tree dari tiap frequent itemset, selanjutnya adalah menentukan suffix dari tiap frequent itemset, seperti pada Tabel 7. Hasil frequent :

Tabel 7. Hasil Frequent Pattern

Suffix	Frequent Pattern
F	{F,A}
M	{M,E}
D	{D,C}{D,E}
B	{B,C}
E	{E,C}

Dari hasil frequent pattern yang didapatkan, langkah selanjutnya yaitu mencari subset dari masing-masing kode_barang, seperti pada Tabel 8:

Tabel 8. Pembentukan Subset

Item	Subset
F	{F,A}
	{A,F}
M	{M,E}
	{E,M}
D	{D,C}
	{C,D}
	{D,E}
	{E,D}
B	{B,C}
	{C,B}
E	{E,C}
	{C,E}

Setelah *frequent pattern* dan *subset* diketahui maka hasilrule dalam penentuan barang-barang yang memenuhi *minimum confidence*.

Tabel 9. Paket Barang Dalam Bentuk Awal

Rule	Support	Confidence
D→C	20%	100%
E→C	26.7%	80%
C→E	26.7%	57.1%

Setelah didapatkan bentuk awal paket barang, maka tahap selanjutnya adalah dilakukan proses lookup ke tabel barang. Hasil lookup ke tabel barang ditampilkan di tabel 10.berikut :

Tabel 10. Hasil Pemaketan Rules

Rule	Paket Produk
D→C	Jika konsumen membeli Kopi Mak Angah Kecil, maka Gula Biasa 1kg juga dibeli dengan <i>confidence</i> 100%
E→C	Jika konsumen membeli Prendjak Teh Celup 30, maka Gula Biasa 1kg juga dibeli dengan <i>confidence</i> 80%
C→E	Jika konsumen membeli Gula Biasa 1kg, maka Prendjak Teh Celup 30 juga dibeli dengan <i>confidence</i> 57.1%

Dalam penentuan kombinasi barang yang akan dijual dalam bentuk paket pihak minimarket Ulfamart memiliki batasan khusus, yaitu :

1. Harga perpaket didapatkan dari pengurangan ke ribuan atau puluhribuan terdekat. Misalkan jumlah harga dari paket 1 sebesar Rp.33.200 maka akan dikurangi menjadi Rp. 30.000.
2. Harga perpaket minimal sebesar Rp.20.000 dan maksimal Rp. 80.000.
3. Jumlah barang yang dapat dipaketkan yaitu sebanyak 2 barang.

Dari batasan yang dimiliki oleh minimarket Ulfamart maka didapatkan rekomendasi paket sebagai berikut :

Tabel 11. Informasi paket

Paket	Paket Item Produk
Paket A	Kopi Mak Angah Kecil, Gula Biasa 1kg.
Paket B	Prendjak Teh Celup 30, Gula Biasa 1kg

Dari hasil pengolahan data ini kita dapat mengambil sebuah keputusan mana barang yang cocok untuk dijadikan sebuah paket penjualan barang. Jika ingin membuat paket penjualan barang dengan jumlah barang lebih dari dua maka data penjualan yang digunakan harus ditambahkan dan nilai support harus diturunkan agar rules yang didapatkan menghasilkan lebih dari dua buah kombinasi barang sehingga paket dapat dibentuk dengan jumlah item lebih banyak.

IV. KESIMPULAN DAN SARAN

Kesimpulan

1. Proses pelatihan dengan menggunakan 15 data sampel telah dianalisa berdasarkan data transaksi penjualan yang telah melewati tahapan preprocessing untuk mendapatkan kombinasi item produk yang dapat dijadikan sebuah paket hemat, di mana menghasilkan 5 rekomendasi paket hemat yang masing-masing paketnya sudah memenuhi batasan khusus dari pihak minimarket.
2. Algoritma Fp-Growth memampatkan kumpulan data sebuah FP-tree, memindai database dua kali, tidak menghasilkan item kandidat dalam proses penambangan, dan sangat efisien untuk penambangan.
3. Proses pengujian pertama dengan

15 data transaksi penjualan menghasilkan 8 rules yang memenuhi minimum support sebesar 0,2 dan minimum confidence sebesar 0,5. pengujian lanjut dengan data yang lebih banyak yaitu 60 data transaksi penjualan menghasilkan 7 rules yang memenuhi minimum support sebesar 0,1 dan minimum confidence sebesar 0,5

Saran

1. Jika ingin membuat paket penjualan barang dengan jumlah barang lebih dari dua maka data penjualan yang digunakan harus ditambahkan dan nilai support harus diturunkan agar rules yang didapatkan menghasilkan lebih dari dua buah kombinasi barang sehingga paket dapat dibentuk dengan jumlah item lebih banyak.
2. Pada penelitian selanjutnya, untuk mendapatkan sebuah pola asosiasi dapat menggunakan algoritma lain agar bisa dilakukan perbandingan.

REFERENSI

- Bi Dan, Thanh Thi et al (2015). "Implementasi Iterative Dichotomiser 3 Pada Data Kelulusan Mahasiswa S1 di Universitas Sebelas Maret". *Jurnal ITSMART*, Volume 4, Nomor 2, Desember 2015.
- Dwi Meilani, Budanis dan Muhammad Asadulloh. "Data Mining untuk Menggali Pola Mahasiswa Baru Menggunakan Metode Frequent Pattern Growth (Studi Kasus : Institut Teknologi Adhi Tama Surabaya)". *Jurnal ITATS*. Diambil dari: jurnal.itats.ac.id/wp-content/.../11/jurnal-Budanis-kirim-itats2.pdf (24 mei 2017)
- Kurniawati, Anis (2014). "educational data mining (konsep dan penerapan)". *Jurnal*

Teknologi Informasi Vol. 4 No. 2, 2013

- Marisa, Fitri (2013). "Pemetaan Pola Hubungan Program Studi Dengan Algoritma Apriori – Studi Kasus Spmu Unnes". *Edu Komputika Journal*, Volume 1, Nomor 1, 2014
- Mehay, Ankur et al (2013). "Analyze Market Basket Data using FP-growth and Apriori Algorithm". *International Journal on Recent and Innovation Trends in Computing and Communication*, Volume: 1 Issue: 9, 2013
- Neesha, Sharma dan Chander Kant Verma (2014). "Association Rule Mining: An Overview". *IJCSC*, Volume 5, Number 1, Maret 2014.
- Nurani dan Hamdan Ghani (2017), "Analisis Keterkaitan Data Transaksi Penjualan Buku Menggunakan Algoritma Apriori dan Algoritma Centroid Linkage Hierarchical Method (Clhm)". *ILKOM Jurnal Ilmiah*. Volume 9, Nomor 1, April 2017
- Rahmat, Brilian (2017). "Implementasi K-Means Clustering pada Rapidminer untuk Analisis Daerah Rawan Kecelakaan". *Seminar Nasional Riset Kuantitatif Terapan 2017*
- Santony, Julius (2012). "Implementasi Data Mining dengan Metode Market Basket Analysis". *Jurnal Teknologi Informasi & Pendidikan*. Vol. 5 No. 2 September 2012
- Tampubolon, Kennedy et al, (2013). "Implementasi Data Mining Algoritma Apriori pada Sistem Persediaan Alat-Alat

Kesehatan”.Informasi dan Teknologi
Ilmiah (INTI). Volume
1, nomor 1, Oktober 2013
Venkatachari, Khavita &Issac Davanbu
Chandrasekaran, (2016). “Market
Basket Analysis Using FP Growth
and Apriori Algorithm: A Case
Study of Mumbai Retail
Store”.BVIMSR’S Journal of
Management Research, Vol. 8
Issue- 1 : april : 2016

Yanto, Robi dan Riri Khoiriah,
(2015).“Implementasi Data Mining
dengan Metode Algoritma Apriori
dalam Menentukan Pola Pembelian
Obat”. Citec Journal, Volume 2,
Nomor 2, April 2015
Yi Zeng et al, (2015).“Research of
Improved FP-Growth Algorithm in
Association Rules Mining”.Hindawi
Publishing Corporation Scientific
Programming, Volume 2015