

# IMPLEMENTASI METODE ASOSIASI *APRIORI* UNTUK MENGETAHUI POLA BELI KONSUMEN DAN REKOMENDASI PENEMPATAN PRODUK PADA SWALAYAN XYZ

Muchamad Taufiq Anwar<sup>1</sup>, Hindriyanto Dwi Purnomo<sup>2</sup>, Mega Novita<sup>3</sup>, Clara Hetty Primasari<sup>4</sup>

<sup>1</sup>Program Studi Teknik Informatika, Fakultas Teknologi Informasi, Universitas Stikubank

<sup>2</sup>Program Studi Sistem Informasi, Fakultas Teknologi Informasi, Universitas Kristen Satya Wacana

<sup>3</sup>Program Studi Informatika, Fakultas Teknik dan Informatika, Universitas PGRI Semarang

<sup>4</sup>Program Studi Sistem Informasi, Fakultas Teknologi Industri, Universitas Atma Jaya Yogyakarta

e-mail: <sup>1</sup>taufiq@edu.unisbank.ac.id, <sup>2</sup>hindriyanto.purnomo@staff.uksw.edu, <sup>3</sup>novita@upgris.ac.id,

<sup>4</sup>clara.hetty@uajy.ac.id

## Abstrak

Bisnis retail merupakan bisnis yang keberhasilannya sangat dipengaruhi oleh kemampuan untuk memahami perilaku konsumen dan kesigapan respons dari pemiliknya. Memahami konsumen dapat dilakukan dengan mempelajari data historis dari transaksi konsumen. Metode *association rule-mining* dalam *Machine Learning* dapat kita manfaatkan untuk menemukan tren pola perilaku beli konsumen yang menunjukkan keterkaitan antar produk / kategori produk. Penelitian ini bertujuan untuk menemukan tren asosiasi kategori produk serta memberikan rekomendasi penempatan produk (*product placement layouting*) dengan memaksimalkan *exposure* pembeli terhadap produk-produk yang terkait saat berbelanja suatu barang dengan harapan akan terjadi peningkatan penjualan. Sebanyak 12.760 data transaksi digunakan untuk menemukan tren asosiasi antar barang yang beli konsumen. Berdasarkan tren asosiasi ini, dibuatlah rekomendasi *layout* peletakan produk untuk memaksimalkan *exposure* barang terkait saat konsumen berbelanja suatu barang sehingga diharapkan akan terjadi peningkatan penjualan.

**Kata Kunci:** market basket analysis, apriori association analysis, retail layout

## 1. PENDAHULUAN

Bisnis retail merupakan bisnis dengan tingkat kompetisi yang sangat tinggi. Keberhasilan bisnis retail sangat dipengaruhi oleh kemampuan untuk memahami perilaku konsumen dan kesigapan respons dari pemilik usaha retail. Bisnis retail harus berfokus kepada konsumennya karena ia merupakan pemain penting di ujung rantai distribusi[1]. Memahami konsumen dapat dilakukan dengan mempelajari data historis dari transaksi konsumen[2]. Metode *association rule-mining* dalam *Machine Learning* memungkinkan kita untuk dapat melihat tren pola perilaku beli konsumen yang menunjukkan keterkaitan antar kategori produk maupun antar produk secara individual. Produk yang dipilih konsumen ketika berbelanja akan menunjukkan preferensi keterkaitan antara produk-produk. Dengan mengetahui tren asosiasi produk yang dibeli konsumen, pemilik retail dapat mendesain *layout* peletakan produk yang dapat membuat konsumen tergerak untuk berbelanja lebih banyak[2]. Penelitian ini bertujuan untuk mengetahui pola keterkaitan produk-produk di Swalayan XYZ berdasarkan data historis pembelian di swalayan tersebut. Berdasarkan pola keterkaitan tersebut akan diberikan rekomendasi penempatan produk untuk meningkatkan penjualan.

## 2. TINJAUAN PUSTAKA

### 2.1 Market Basket Analysis

*Market Basket Analysis* adalah metode analisis komposisi barang-barang yang dibeli konsumen dalam setiap pembelian yang dilakukan. Data mentah untuk *market basket analysis* biasanya berupa struk pembelian. *Market basket analysis* bertujuan untuk

menemukan pola keterkaitan barang yang dibeli secara bersamaan[2]. Misalnya, seseorang yang membeli susu biasanya juga akan membeli roti. Aturan (*rules*) keterkaitan antar barang biasanya dinyatakan dalam format sebagai berikut:

$$IF \{susu\} THEN \{roti\}$$

Pemilik retail dapat memanfaatkan informasi ini dengan menempatkan barang-barang yang berkaitan saling berdekatan sehingga lebih mudah terlihat dan terjangkau oleh konsumen saat berbelanja. Cara penempatan ini dapat mempengaruhi perilaku beli konsumen dan meningkatkan penjualan untuk barang yang berkaitan [1].

### 2.1 Association Rules

Sebuah *association rule* adalah pernyataan implikasi dalam bentuk  $X \rightarrow Y$ , di mana  $X$  dan  $Y$  adalah dua item yang berbeda. Kekuatan *association rules* dapat diukur melalui besaran *support* dan *confidence*. *Support* menunjukkan seberapa sering aturan (*rule*) tersebut dapat diterapkan pada suatu set data, sedangkan *confidence* menunjukkan seberapa sering item  $Y$  muncul dalam transaksi yang melibatkan  $X$ [3]. Definisi formal dari *support* dan *confidence* ditunjukkan dengan persamaan (1) dan (2).

$$Support, S(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{N} \quad (1)$$

$$Confidence, C(X \rightarrow Y) = \frac{\sigma(X \cup Y)}{\sigma(X)} \quad (2)$$

### 2.1 Metode Asosiasi Apriori

*Association analysis* merupakan cabang *Machine Learning* yang berguna dalam menemukan keterkaitan (*association rule*) yang tersembunyi dalam sebuah dataset yang besar. Metode penentuan aturan asosiasi (*association rule mining*) pertama kali dikemukakan oleh Agrawal, et. al. pada tahun 1993[4]. Metode ini telah lama digunakan pada analisis data transaksi seperti *Market Basket Analysis*[3].

Dalam *association analysis*, prinsip *apriori* menyatakan bahwa: Jika suatu *itemset* (barang yang dibeli bersamaan) sering muncul (*support*-nya tinggi), maka semua *subset*-nya juga pasti akan sering muncul. Dalam menemukan *association rule*, metode asosiasi *apriori* akan membuang *itemset* yang tidak mencapai batas minimal *support* tertentu (*support-based pruning*). Metode *apriori* menemukan *association rule* dimulai dengan menghitung *support* untuk 1-*itemset* dan secara iteratif menambahkan satu item ke dalam *itemset* dan mengevaluasi *support*-nya[3]. Pseudocode Algoritma *Apriori* ditunjukkan pada Algoritma 1.

Kode Program 1. Pseudocode Algoritma *Apriori*

```

1:  $k = 1$ .
2:  $F_k = \{ i \mid i \in I \wedge \sigma(\{i\}) \geq N \times \text{minsup} \}$ . {Find all frequent 1-itemsets}
3: repeat
4:    $k = k + 1$ .
5:    $C_k = \text{apriori-gen}(F_{k-1})$ . {Generate candidate itemsets}
6:   for each transaction  $t \in T$  do
7:      $C_t = \text{subset}(C_k, t)$ . {Identify all candidates that belong to  $t$ }
8:     for each candidate itemset  $c \in C_t$  do
9:        $\sigma(c) = \sigma(c) + 1$ . {Increment support count}
10:    end for
11:  end for
12:   $F_k = \{ c \mid c \in C_k \wedge \sigma(c) \geq N \times \text{minsup} \}$ . {Extract the frequent k-itemsets}
13: until  $F_k = \emptyset$ 
14: Result =  $\cup F_k$ .

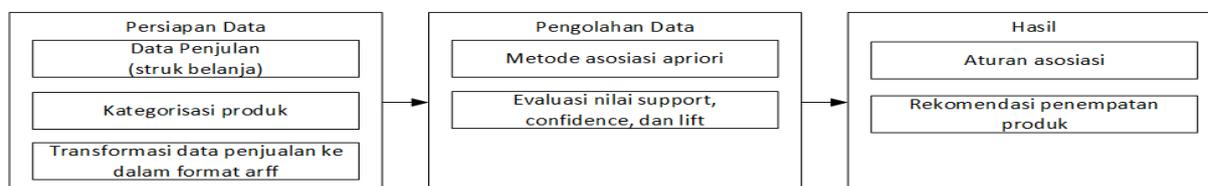
```

Dalam perkembangannya, metode asosiasi *apriori* telah mengalami modifikasi seperti yang baru-baru ini dilakukan oleh Yuan[5]. Beberapa perbaikan yang dilakukan yaitu: 1) penggunaan cara pemetaan basis data baru untuk menghindari pemindaian basis data yang berulang kali; 2) pemangkasan lebih lanjut pada *frequent-itemset* dan itemset kandidat untuk meningkatkan efisiensi penggabungan; 3) penggunaan strategi tumpang tindih (*overlap*) untuk menghitung *support* untuk mencapai efisiensi algoritma yang tinggi. Modifikasi yang diusulkan ini terbukti meningkatkan efisiensi operasi dibandingkan dengan modifikasi algoritma lainnya yang sudah ada. Sebuah metode apriori baru juga telah diajukan dengan memanfaatkan *frequent matrix* yang diberi nama *Frequent Matrix Apriori* (FMA) [6].

Metode asosiasi apriori pada riset-riset terkini telah dipakai dalam beberapa kasus, misalnya untuk memberikan rekomendasi produk pada *mobile e-commerce* [7][8], untuk evaluasi pendidikan[9], memprediksi daerah banjir[10], memahami konektivitas bagian-bagian otak[11], memprediksi perilaku penggunaan web pengguna[12], mengetahui asosiasi antara penggunaan obat-obatan dan kejadian buruk dalam Farmakoterapi pada pasien *non-small cell lung cancer* (NSCLC)[13], memprediksi penyakit *dengue*[14], serta memahami karakteristik Flavivirus (termasuk Zika virus)[15].

### 3. METODE

Untuk dapat mengetahui pola beli konsumen, langkah pertama yang dilakukan adalah mengambil basis data penjualan dan produk dari aplikasi kasir (*Point of Sales*) pada swalayan XYZ. Data penjualan menunjukkan produk-produk yang terjual dalam sebuah transaksi yang biasanya tergambar dalam sebuah struk belanja. Produk-produk yang muncul dalam transaksi kemudian dikelompokkan ke dalam 23 kategori seperti yang ditunjukkan pada Tabel 1. Langkah berikutnya, setiap data transaksi akan ditransformasikan ke dalam format *file arff* untuk dapat diolah dengan perangkat lunak WEKA (*Waikato Environment for Knowledge Analysis*). Setiap transaksi akan menjadi sebuah baris data yang berisi daftar item / kategori produk dengan 23 kolom yang menunjukkan 23 kategori produk. Jika sebuah produk ada di dalam transaksi, maka akan diberikan label “t” (*true*), jika tidak, maka diberikan label “?”. Contoh data transaksi dalam format *file arff* ditunjukkan pada gambar 2. Data dalam format *arff* ini berikutnya akan diproses dengan algoritma asosiasi apriori dengan perangkat lunak WEKA. Untuk setiap *association rules* yang ditemukan, akan dievaluasi nilai *support*, *confidence*, dan *lift*-nya. Hasil dari proses ini berupa aturan asosiasi yang menunjukkan tren pola beli konsumen di swalayan XYZ. Berdasarkan aturan asosiasi yang ditemukan, maka dibuatlah rekomendasi penempatan produk untuk meningkatkan penjualan.



Gambar 1. Metode penelitian

Tabel 1. Kategori produk

makanan_ringan	minuman_siap	produk_bayi
permen_coklat	minuman_bahan	insektisida_pengharum
biskuit_wafer	susu	es_krim
roti_basah	kosmetik	asesoris
makanan_instan	rokok_korek	mainan
makanan_siap	obat	pembalut_kapas_tisu
sembako	alat_kebersihan	perlengkapan_rumah_tangga
bumbu_meses	kebutuhan_mandi	

```

27 @data
28 ?, ?, ?, ?, ?, ?, ?, ?, t, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?
29 ?, ?, ?, ?, ?, ?, ?, ?, t, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?
30 ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, t, ?, ?, ?, ?, ?, ?
31 ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, t, ?, ?, ?, ?, ?, ?
32 ?, t, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?
33 ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, t, ?, ?, ?, ?, ?, ?
34 ?, ?, ?, ?, ?, t, t, ?, ?, ?, ?, ?, t, ?, t, ?, ?, ?, ?, ?, ?
35 ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, ?, t, t, ?, ?, ?, ?, ?, ?
    
```

Gambar 2. Contoh data transaksi dalam format arff

#### 4. HASIL DAN PEMBAHASAN

Penelitian ini menggunakan 12.760 data transaksi pada bulan April dan Mei 2015. Hasil analisis data transaksi menggunakan metode asosiasi *apriori* dengan iterasi sebanyak 25 kali ( $\delta = 0,04$ ),  $\text{minimum confidence} = 0,2$  dan  $\text{minimum support} = 0,02$  ditunjukkan pada Tabel 2. Beberapa contoh tren asosiasi barang yang muncul dengan *support* dan *confidence* yang tinggi antara lain adalah:

- a. Jika konsumen membeli biskuit / wafer dan minuman siap, maka dalam 55% persen kasus mereka juga akan membeli makanan ringan.
- b. Jika konsumen membeli peralatan kebersihan, maka dalam 38% kasus mereka juga akan membeli kebutuhan mandi.
- c. Jika konsumen membeli bumbu / meses, maka dalam 36% kasus mereka juga akan membeli sembako.
- d. Jika konsumen membeli kosmetik, maka dalam 35% kasus mereka juga akan membeli kebutuhan mandi.

Pola (a) dapat dipahami bahwa memang banyak konsumen yang datang ke swalayan untuk membeli camilan sekaligus dengan minuman. Konsumen yang melakukan hal ini biasanya mereka yang sedang dalam perjalanan dan mampir ke swalayan untuk membeli camilan dan minuman siap. Walaupun tidak menutup kemungkinan bahwa konsumen seperti anak-anak dan warga sekitar juga akan melakukan hal yang sama. Pola (b) menunjukkan pola pembelian konsumen yang sudah berkeluarga seperti seorang ibu ataupun ayah yang berbelanja secara rutin untuk kebutuhan rumah tangga yaitu peralatan kebersihan dan kebutuhan mandi. Pola (c) juga menunjukkan pola beli konsumen rumah tangga (utamanya ibu-ibu) yang membeli bumbu bersamaan dengan sembako. Sedangkan pola (d) merupakan pola keterkaitan antara pembelian kosmetik dan kebutuhan mandi yang sangat mungkin terjadi pada konsumen segala umur dan gender, meski lebih cenderung ke konsumen perempuan.

Contoh penghitungan nilai *support* dan *confidence* untuk pola (b) adalah sebagai berikut:

$$\text{Support}, S(\text{alat}_{\text{kebersihan}} \rightarrow \text{kebutuhan}_{\text{mandi}}) = \frac{\sigma(\text{alat}_{\text{kebersihan}} \cup \text{kebutuhan}_{\text{mandi}})}{N}$$

$$S(\text{alat}_{\text{kebersihan}} \rightarrow \text{kebutuhan}_{\text{mandi}}) = \frac{(1415 \cup 535)}{12760} = \frac{537}{12760} = 0,042$$

$$\text{Confidence}, C(\text{alat}_{\text{kebersihan}} \rightarrow \text{kebutuhan}_{\text{mandi}}) = \frac{\sigma(\text{alat}_{\text{kebersihan}} \cup \text{kebutuhan}_{\text{mandi}})}{\sigma(\text{alat}_{\text{kebersihan}})}$$

$$C(\text{alat}_{\text{kebersihan}} \rightarrow \text{kebutuhan}_{\text{mandi}}) = \frac{(1415 \cup 537)}{(1415)} = \frac{537}{1415} = 0,38$$

Nilai *support* sebesar 0,042 berarti bahwa terdapat 4,2% data transaksi yang mendukung pola beli “alat\_kebersihan → kebutuhan\_mandi” dari keseluruhan data transaksi yang ada, atau sebanyak 537 kasus dari 12760 transaksi. Sementara nilai *confidence* sebesar

0,38 berarti bahwa terdapat 38% persen transaksi (537 transaksi dari 1415 transaksi) di mana konsumen yang membeli alat kebersihan juga membeli kebutuhan mandi (sementara 62% konsumen yang membeli alat kebersihan tidak disertai dengan membeli produk kebutuhan mandi).

Tabel 2. Temuan *association rules*

<i>Antecedent</i>	<i>Antecedent Support (*1/12760)</i>	<i>Consequent</i>	<i>Consequent Support (*1/12760)</i>	<i>Confidence</i>
biskuit_wafer, minuman_siap	509	makan_ringan	278	0,55
makan_ringan, biskuit_wafer	614	minuman_siap	278	0,45
biskuit_wafer	1388	makan_ringan	614	0,44
alat_kebersihan	1415	kebutuhan_mandi	537	0,38
makan_ringan	2525	minuman_siap	953	0,38
biskuit_wafer	1388	minuman_siap	509	0,37
bumbu_meses	780	sembako	279	0,36
kosmetik	1274	kebutuhan_mandi	450	0,35
minuman_bahan	1336	sembako	469	0,35
permen_coklat	1471	minuman_siap	512	0,35
roti	1094	makan_ringan	377	0,34
kebutuhan_mandi	1618	alat_kebersihan	537	0,33
roti	1094	minuman_siap	362	0,33
makan_instan	1610	sembako	525	0,33
permen_coklat	1471	makan_ringan	469	0,32
makan_instan	1610	makan_ringan	475	0,3
pembalut_kapas_tisu	1013	kebutuhan_mandi	297	0,29
makan_ringan, minuman_siap	953	biskuit_wafer	278	0,29
alat_kebersihan	1415	sembako	406	0,29
kebutuhan_mandi	1618	kosmetik	450	0,28
minuman_siap	3430	makan_ringan	953	0,28
minuman_bahan	1336	makan_ringan	371	0,28
makan_instan	1610	minuman_siap	422	0,26
pembalut_kapas_tisu	1013	alat_kebersihan	259	0,26
minuman_bahan	1336	makan_instan	335	0,25
sembako	2122	makan_instan	525	0,25
minuman_bahan	1336	minuman_siap	327	0,24
makan_ringan	2525	biskuit_wafer	614	0,24
minuman_bahan	1336	kebutuhan_mandi	323	0,24
kebutuhan_mandi	1618	makan_ringan	391	0,24
alat_kebersihan	1415	makan_ringan	341	0,24
kebutuhan_mandi	1618	sembako	380	0,23
alat_kebersihan	1415	minuman_siap	319	0,23
kebutuhan_mandi	1618	minuman_siap	359	0,22
sembako	2122	minuman_bahan	469	0,22
makan_instan	1610	kebutuhan_mandi	354	0,22
kebutuhan_mandi	1618	makan_instan	354	0,22
kosmetik	1274	alat_kebersihan	278	0,22

alat_kebersihan	1415	makan_instan	300	0,21
minuman_bahan	1336	alat_kebersihan	281	0,21
biskuit_wafer	1388	permen_coklat	291	0,21
makan_instan	1610	minuman_bahan	335	0,21
es_krim	1377	minuman_siap	276	0,2
biskuit_wafer	1388	makan_ringan, minuman_siap	278	0,2

Untuk membantu mengelompokkan kategori barang yang berkaitan, kami menjalankan analisis sekali lagi dengan *me-rangking* tingkat keterhubungan antar kategori melalui besaran *lift*. *Lift* didefinisikan sebagai  $lift = support(X,Y) / support(X).support(Y)$ . Jika nilai *lift* = 1, maka X dan Y saling berdiri sendiri. Nilai *lift* yang tinggi menunjukkan adanya keterkaitan khusus antara X dan Y yang bukan sekedar kebetulan. Hasil analisis *lift* untuk data transaksi swalayan XYZ dengan iterasi sebanyak 25 kali ( $\delta = 0,04$ ), *minimum lift* = 1,1 dan *minimum support* = 0,02 ditunjukkan pada Tabel 3.

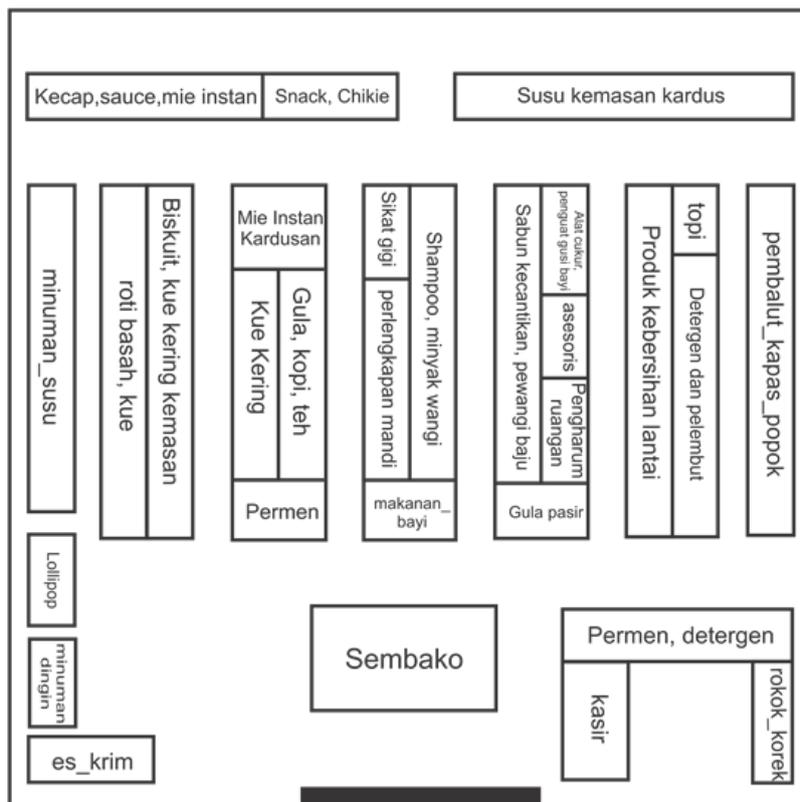
Hasil analisis *lift* cenderung mengkonfirmasi ulang bahwa memang ada keterkaitan yang kuat antara barang-barang dalam hasil temuan pola asosiasi pada tabel 2. Setiap pasangan barang yang terkait akan muncul sebanyak dua kali dalam tabel 3 karena *lift* memang mengukur keterkaitan antar barang baik dari X ke Y maupun dari Y ke X yang akan memberikan nilai *lift* yang sama, tetapi nilai *confidence* yang berbeda. Nilai *confidence* yang berbeda disebabkan oleh nilai *support* kasus X dan Y yang berbeda ketika berada pada posisi *antecedent* dan *consequent*.

Tabel 3. Temuan analisis *lift*

No	<i>Antecedent</i>	<i>Consequent</i>	<i>Lift</i>	<i>Confidence</i>
1	kebutuhan_mandi	alat_kebersihan	2,99	0,33
2	alat_kebersihan	kebutuhan_mandi	2,99	0,38
3	kebutuhan_mandi	kosmetik	2,79	0,28
4	kosmetik	kebutuhan_mandi	2,79	0,35
5	makan_ringan	biskuit_wafer, minuman_siap	2,76	0,11
6	biskuit_wafer, minuman_siap	makan_ringan	2,76	0,55
7	biskuit_wafer	makan_ringan, minuman_siap	2,68	0,20
8	makan_ringan, minuman_siap	biskuit_wafer	2,68	0,29
9	kebutuhan_mandi	pembalut_kapas_tisu	2,31	0,18
10	alat_kebersihan	pembalut_kapas_tisu	2,31	0,18
11	pembalut_kapas_tisu	kebutuhan_mandi	2,31	0,29
12	pembalut_kapas_tisu	alat_kebersihan	2,31	0,26
13	makan_ringan	biskuit_wafer	2,24	0,24
14	biskuit_wafer	makan_ringan	2,24	0,44
15	sembako	bumbu_meses	2,15	0,13
16	bumbu_meses	sembako	2,15	0,36
17	sembako	minuman_bahan	2,11	0,22
18	minuman_bahan	sembako	2,11	0,35
19	makan_instan	minuman_bahan	1,99	0,21
20	minuman_bahan	makan_instan	1,99	0,25
21	alat_kebersihan	kosmetik	1,97	0,20
22	kosmetik	alat_kebersihan	1,97	0,22
23	sembako	makan_instan	1,96	0,25
24	makan_instan	sembako	1,96	0,33
25	kebutuhan_mandi	minuman_bahan	1,91	0,20

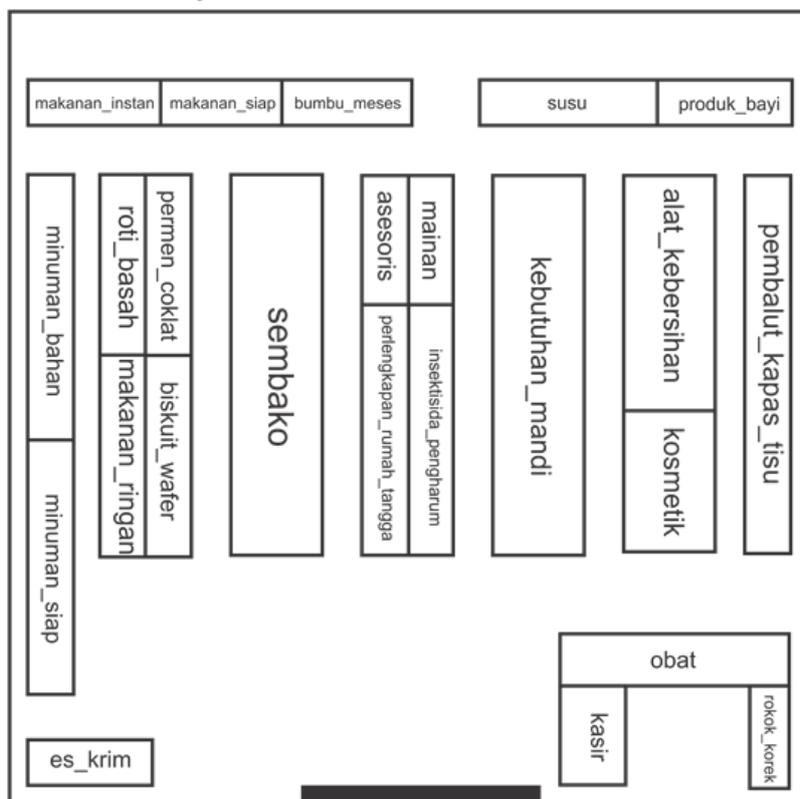
26	minuman_bahan	kebutuhan_mandi	1,91	0,24
27	alat_kebersihan	minuman_bahan	1,90	0,20
28	minuman_bahan	alat_kebersihan	1,90	0,21
29	permen_coklat	biskuit_wafer	1,82	0,20
30	biskuit_wafer	permen_coklat	1,82	0,21
31	makan_ringan	Roti	1,74	0,15
32	roti	makan_ringan	1,74	0,34
33	sembako	alat_kebersihan	1,73	0,19
34	kebutuhan_mandi	makan_instan	1,73	0,22
35	makan_instan	kebutuhan_mandi	1,73	0,22
36	alat_kebersihan	sembako	1,73	0,29
37	minuman_siap	makan_ringan, biskuit_wafer	1,68	0,08
38	makan_instan	alat_kebersihan	1,68	0,19
39	alat_kebersihan	makan_instan	1,68	0,21
40	makan_ringan, biskuit_wafer	minuman_siap	1,68	0,45
41	makan_ringan	permen_coklat	1,61	0,19
42	permen_coklat	makan_ringan	1,61	0,32
43	makan_instan	biskuit_wafer	1,58	0,17
44	biskuit_wafer	makan_instan	1,58	0,20
45	makan_ringan	makan_instan	1,49	0,19
46	makan_instan	makan_ringan	1,49	0,30
47	sembako	kebutuhan_mandi	1,41	0,18
48	kebutuhan_mandi	sembako	1,41	0,23
49	minuman_siap	makan_ringan	1,40	0,28
50	makan_ringan	minuman_siap	1,40	0,38
51	makan_ringan	minuman_bahan	1,40	0,15
52	minuman_bahan	makan_ringan	1,40	0,28
53	minuman_siap	biskuit_wafer	1,36	0,15
54	biskuit_wafer	minuman_siap	1,36	0,37
55	minuman_siap	permen_coklat	1,29	0,15
56	permen_coklat	minuman_siap	1,29	0,35
57	minuman_siap	Roti	1,23	0,11
58	roti	minuman_siap	1,23	0,33
59	makan_ringan	kebutuhan_mandi	1,22	0,15
60	makan_ringan	alat_kebersihan	1,22	0,14
61	kebutuhan_mandi	makan_ringan	1,22	0,24
62	alat_kebersihan	makan_ringan	1,22	0,24

Berdasarkan temuan *rules* dan ranking *lift* tersebut, kami memberikan saran *layout* baru untuk peletakan produk dengan tujuan memaksimalkan *exposure* barang terkait saat konsumen berbelanja suatu barang. *Layout* disusun dengan cara menata barang-barang yang berkaitan erat secara berdekatan. Dengan penataan yang seperti ini, konsumen yang terlah terbiasa melaukan pembelian barang secara berpasangan akan menjadi dimudahkan karena dekat untuk menjangkau barang kebutuhan berikutnya, sementara untuk konsumen yang terbiasa untuk membeli salah satu dari pasangan barang akan terdorong untuk membeli barang pasangannya. Perbandingan antara *layout* lama dan *layout* baru ditunjukkan pada Gambar 3.



Jalan masuk

A



Jalan masuk

B

Gambar 3. Denah penempatan produk sebelum (A) dan sesudah (B).

## 5. KESIMPULAN

Memahami konsumen sangat diperlukan dalam usaha retail. Metode asosiasi dalam Machine Learning dapat kita manfaatkan untuk menemukan tren pola perilaku beli konsumen yang menunjukkan keterkaitan antar produk. Dengan menganalisis data historis dari perilaku berbelanja konsumen, penelitian ini menemukan tren asosiasi antar kategori barang yang dibeli. Berdasarkan tren asosiasi ini, dibuatlah rekomendasi *layout* peletakan produk untuk memaksimalkan *exposure* barang terkait saat konsumen berbelanja suatu barang sehingga diharapkan akan terjadi peningkatan penjualan.

## DAFTAR PUSTAKA

- [1] I. Surjandari and A. Seruni, "Design of product placement layout in retail shop using market basket analysis," *Makara J. Technol.*, vol. 9, no. 2, pp. 43–47, 2010.
- [2] D. L. Olson and D. Delen, *Advanced data mining techniques*. Springer Science & Business Media, 2008.
- [3] P.-N. Tan, M. Steinbach, and V. Kumar, "Association analysis: basic concepts and algorithms," in *Introduction to Data mining*, vol. 321321367, Addison-Wesley Boston, MA, 2005.
- [4] R. Agrawal, T. Imieliński, and A. Swami, "Mining association rules between sets of items in large databases," in *Acm sigmod record*, 1993, vol. 22, no. 2, pp. 207–216.
- [5] X. Yuan, "An improved Apriori algorithm for mining association rules," in *AIP conference proceedings*, 2017, vol. 1820, no. 1, p. 80005.
- [6] K. Niu, H. Jiao, Z. Gao, C. Chen, and H. Zhang, "A developed apriori algorithm based on frequent matrix," in *ACM International Conference Proceeding Series*, 2017, pp. 55–58.
- [7] Y. Guo, M. Wang, and X. Li, "Application of an improved Apriori algorithm in a mobile e-commerce recommendation system," *Ind. Manag. Data Syst.*, vol. 117, no. 2, pp. 287–303, 2017.
- [8] S. Bandyopadhyay, S. S. Thakur, and J. K. Mandal, "Product recommendation for E-commerce data using association rule and apriori algorithm," in *Advances in Intelligent Systems and Computing*, 2019, vol. 749, pp. 585–593.
- [9] C. L. Mao, S. L. Zou, and J. H. Yin, "Educational evaluation based on Apriori-Gen algorithm," *Eurasia J. Math. Sci. Technol. Educ.*, vol. 13, no. 10, pp. 6555–6564, 2017.
- [10] N. A. Harun, M. Makhtar, A. A. Aziz, Z. A. Zakaria, F. S. Abdullah, and J. A. Jusoh, "The application of apriori algorithm in predicting flood areas," *Int. J. Adv. Sci. Eng. Inf. Technol.*, vol. 7, no. 3, pp. 763–769, 2017.
- [11] Z. Niu, Y. Nie, Q. Zhou, L. Zhu, and J. Wei, "A brain-region-based meta-analysis method utilizing the Apriori algorithm," *BMC Neurosci.*, vol. 17, no. 1, p. 23, 2016.
- [12] J. Yang, H. Huang, and X. Jin, "Mining web access sequence with improved apriori algorithm," in *2017 IEEE International Conference on Computational Science and Engineering (CSE) and IEEE International Conference on Embedded and Ubiquitous Computing (EUC)*, 2017, vol. 1, pp. 780–784.
- [13] W. Chen, J. Yang, H.-L. Wang, Y.-F. Shi, H. Tang, and G.-H. Li, "Discovering Associations of Adverse Events with Pharmacotherapy in Patients with Non-Small Cell Lung Cancer Using Modified Apriori Algorithm," *Biomed Res. Int.*, vol. 2018, 2018.
- [14] I. Jahangir, A. Hannan, S. Javed, and others, "Prediction of Dengue Disease through Data Mining by using Modified Apriori Algorithm," in *Proceedings of the 4th ACM International Conference of Computing for Engineering and Sciences*, 2018, p. 5.

- [15] Y. Yang, B. Gu, and T. Yoon, “Deeper understanding of Flaviviruses including Zika virus by using Apriori Algorithm and Decision Tree,” in *MATEC Web of Conferences*, 2016, vol. 69, p. 1005.