



Peningkatan Visibilitas Produk pada Rekomendasi Long-Tail dengan Pendekatan Frequent Maximal Itemset

Rosyid Muarif¹, Tubagus Mohammad Akhriza², Eni Farida³

¹²³Program Studi S1 Sistem Informasi

STMIK PPKIA Pradnya Paramita (STIMATA) Malang

akhriza@stimata.ac.id

Abstract

Long-tail products are often overlooked in Collaborative Filtering recommendation systems due to their low purchase frequency and reliance on user interaction history. This study proposes the use of Frequent Maximal Itemset (FMI) to improve the visibility of *long-tail* products in an online electronic cigarette (vape) store. Unlike Collaborative Filtering, FMI does not require user data and identifies historical transaction patterns to recommend relevant *long-tail* products alongside popular ones. Experimental results show that FMI is effective in identifying maximal itemsets that combine popular and *long-tail* products. Validation with 10 users revealed that 90% found the recommendations relevant to the main products they were searching for, and 90% indicated that they were likely to try the recommended *long-tail* products. The *long-tail* products included in the recommendations had logical associations with popular products, such as nicotine liquids with vaping devices. Thus, the FMI approach proves to be more flexible and effective in addressing popularity bias, while also providing *long-tail* products with greater visibility and increasing their potential for sales.

Keywords: long-tail recommendation, frequent maximal itemset, product visibility, Apriori algorithm, PT Mahakarya Distribusi


Abstrak

Produk *long-tail* sering kali terabaikan dalam sistem rekomendasi berbasis Collaborative Filtering, terutama karena rendahnya frekuensi pembelian dan ketergantungan pada riwayat interaksi pengguna. Penelitian ini mengusulkan penggunaan Frequent Maximal Itemset (FMI) untuk meningkatkan visibilitas produk *long-tail* di toko online rokok elektronik (vape). Tidak seperti Collaborative Filtering, FMI tidak memerlukan data pengguna dan mengidentifikasi pola transaksi historis untuk merekomendasikan produk *long-tail* yang relevan bersama produk populer. Hasil eksperimen menunjukkan bahwa FMI efektif dalam menemukan itemset maksimal yang menggabungkan produk populer dan *long-tail*. Validasi terhadap 10 pengguna menunjukkan bahwa 90% merasa rekomendasi relevan dengan produk yang mereka cari, dan 90% menyatakan kemungkinan besar akan mencoba produk *long-tail* yang direkomendasikan. Produk-produk *long-tail* yang muncul dalam rekomendasi memiliki keterkaitan logis dengan produk populer, seperti cairan nikotin dengan perangkat vaping. Dengan demikian, pendekatan FMI terbukti lebih fleksibel dan efektif dalam mengatasi bias popularitas, serta memberikan peluang bagi produk *long-tail* untuk lebih terlihat dan meningkatkan potensi penjualan.

Kata kunci: rekomendasi long-tail, frequent maximal itemset, visibilitas produk, algoritma Apriori, PT Mahakarya Distribusi

1. Pendahuluan

Sistem rekomendasi telah menjadi komponen penting dalam industri digital, khususnya e-commerce, di mana kemampuan untuk menawarkan produk yang relevan dapat meningkatkan keterlibatan pengguna dan penjualan. Salah satu tantangan utama dalam sistem rekomendasi adalah kecenderungan bias terhadap produk-produk populer, yang menyebabkan item-item kurang populer atau dikenal sebagai *long-tail items* kurang terekspos kepada konsumen [1]–[3]. Item-item ini, meskipun memiliki frekuensi pembelian yang rendah, berpotensi memberikan kontribusi signifikan jika diberi visibilitas yang tepat. Ilustrasi mengenai item Populer dan Long-tail dijelaskan melalui Gambar 1 [4].



Gambar 1. Ilustrasi produk populer vs long-tail[4]

Konsep long-tail pertama kali diperkenalkan oleh Chris Anderson, yang menekankan bahwa pasar digital yang luas memungkinkan penjualan produk-produk niche dengan volume kecil namun secara keseluruhan signifikan [4]. Dalam konteks ini, sistem rekomendasi yang efektif harus dapat menyeimbangkan antara mempromosikan produk populer dan long-tail items, agar seluruh portofolio produk dapat dimanfaatkan secara optimal. Beberapa penelitian sebelumnya telah menunjukkan bahwa dengan pendekatan yang tepat, produk long-tail dapat memberikan kontribusi besar terhadap pendapatan perusahaan.

Metode yang paling umum digunakan dalam sistem rekomendasi adalah Collaborative Filtering, yang menganalisis interaksi pengguna untuk memberikan rekomendasi [5], [6]. Namun, metode ini memiliki keterbatasan karena memerlukan informasi login untuk melacak preferensi pengguna, yang tidak selalu tersedia dalam platform dengan banyak pengguna anonim [7]–[9].

Sebagai alternatif, pendekatan Frequent Maximal Itemset (FMI) menawarkan solusi yang lebih fleksibel karena tidak membutuhkan data pengguna, melainkan mengandalkan analisis hubungan antar produk dalam transaksi sebelumnya. Pendekatan ini memungkinkan sistem untuk merekomendasikan produk tanpa bergantung pada identitas pengguna, sehingga lebih sesuai untuk platform dengan pengguna anonim atau sesekali.

FMI adalah bagian dari konsep association rule learning, yang sudah luas penerapannya dalam pengembangan sistem rekomendasi (SR), seperti SR perpustakaan[8], [10], SR e-commerce[7], [9], dan SR job-skill [11], [12], serta SR promosi karir dosen [13]. Namun demikian, secara spesifik, penerapan FMI dalam meningkatkan visibilitas rekomendasi long-tail belum terekspos secara signifikan dalam publikasi ilmiah.

Penelitian ini bertujuan untuk menguji penerapan Frequent Maximal Itemset dalam meningkatkan visibilitas produk long-tail pada PT Mahakarya Distribusi, sebuah perusahaan distribusi dengan dataset transaksi penjualan yang besar. Dengan menggunakan algoritma Apriori, penelitian ini akan mengeksplorasi potensi strategi rekomendasi berbasis itemset maksimal yang dapat memaksimalkan eksposur produk yang kurang populer. Pertanyaan utama yang ingin dijawab adalah apakah pendekatan ini dapat meningkatkan visibilitas long-tail items dan berkontribusi langsung terhadap peningkatan penjualan produk-produk tersebut.

2. Metode Penelitian

Penelitian ini menggunakan data transaksi penjualan dari PT Mahakarya Distribusi, sebuah toko online Rokok Elektronik (vape), yang terdiri dari 15.631 transaksi selama periode Januari hingga Agustus 2023. Setiap transaksi berisi informasi nomor kuitansi (*Receipt Number*), *stock keeping unit* (SKU), dan tanggal

transaksi. Data ini diolah untuk mengidentifikasi *frequent maximal itemsets* menggunakan algoritma Apriori.

2.1. Konsep Frequent Maximal Itemset (FMI)

Frequent Maximal Itemset (FMI) adalah subset dari *frequent itemsets*, di mana FMI hanya mencakup itemset yang tidak bisa diperluas lebih lanjut tanpa menurunkan nilai *support*-nya. Dalam Association Rule Mining, *frequent itemsets* digunakan untuk menemukan hubungan atau asosiasi antar produk dalam transaksi. FMI berfokus pada itemset terbesar yang memenuhi syarat *support*, tanpa harus mempertimbangkan subset yang lebih kecil dan kurang signifikan, sehingga proses analisis menjadi lebih efisien.

FMI juga mampu menyatukan produk populer dan produk *long-tail* atau kurang populer dalam satu itemset. Biasanya, produk populer memiliki nilai *support* yang tinggi, sementara produk *long-tail* sering kali memiliki *support* rendah. Namun, produk *long-tail* ini tetap dapat muncul dalam itemset maksimal yang lebih panjang, karena sering dibeli bersama produk yang lebih populer. Dengan demikian, metode ini memungkinkan produk *long-tail* untuk lebih terlihat oleh konsumen, meningkatkan visibilitasnya dalam rekomendasi.

2.2. Persiapan Data

Data transaksi diimpor dari file CSV dan diolah menggunakan *library* pandas di Python. Setiap transaksi dikelompokkan berdasarkan *Receipt Number* (nomor invoice) dan *Date*, dengan setiap SKU yang muncul dalam satu transaksi digabungkan menjadi satu set item.

Data transaksi diterima dalam bentuk satu invoice per item pembelian, artinya setiap baris data hanya merepresentasikan satu produk yang dibeli dalam satu invoice. Oleh karena itu, sebelum proses analisis dimulai, data perlu diolah menggunakan operasi *group-by* berdasarkan nomor invoice. Hal ini dilakukan untuk menggabungkan semua item yang dibeli dalam satu invoice menjadi satu set item.

Data ini diimpor dari file CSV dan diolah menggunakan *library* pandas di Python. Setiap transaksi dikelompokkan berdasarkan *Receipt Number* dan *Date*, dengan setiap SKU yang muncul dalam satu transaksi digabungkan menjadi satu set item. Dengan proses ini, format data transaksi berubah dari satu baris per item menjadi satu baris per invoice yang berisi seluruh item yang dibeli, dalam bentuk:

```
no_invoice {item1, item2, ..., itemN}
```

Meskipun fokus analisis diarahkan pada penemuan *frequent maximal itemset* yang mengandung 4 hingga 5 SKU untuk mendapatkan *frequent itemsets* yang relevan dalam konteks rekomendasi produk *long-tail*, tidak ada

batasan dalam panjang transaksi yang diproses. Transaksi dengan jumlah SKU yang lebih banyak tetap dipertimbangkan, terutama jika memberikan wawasan yang lebih luas dalam rekomendasi produk.

2.3. Penerapan Algoritma Apriori

Algoritma Apriori diterapkan untuk menemukan *frequent itemsets* yang memenuhi ambang batas *support* minimum sebesar 0,001. Sebelum menjalankan algoritma, dataset dikonversi menjadi format biner (*one-hot encoding*) agar dapat diproses oleh algoritma Apriori. Pustaka Python **mlxtend** digunakan untuk menjalankan Apriori, dan hasil *frequent itemsets* disimpan dalam *DataFrame* untuk analisis lebih lanjut.

Program Algoritma Apriori

```
# Membuat dataset one-hot encoding untuk SKU
basket = filtered_grouped['SKU'].apply(lambda x:
pd.Series(1, index=x)).fillna(0).astype(bool)

# Menjalankan algoritma Apriori dengan
support 0.001
frequent_itemsets = apriori(basket,
min_support=0.001, use_colnames=True)

FI = apriori(basket, min_support=0.001,
use_colnames=True, max_len=1)
```

2.4. Identifikasi Frequent Maximal Itemsets

Setelah *frequent itemsets* ditemukan, dilakukan analisis untuk mengidentifikasi *maximal itemsets*, yaitu itemset terbesar yang tidak dapat diperluas tanpa menurunkan nilai *support*. *Maximal itemsets* ini digunakan sebagai dasar untuk rekomendasi produk, khususnya untuk meningkatkan visibilitas produk *long-tail* yang memiliki *support* rendah namun signifikan dalam transaksi.

Program Frequent Maximal Itemsets

```
# Mencari Maximum Itemsets
def is_maximal(itemset, frequent_itemsets):
for other_itemset in frequent_itemsets['itemsets']:
if itemset != other_itemset and
itemset.issubset(other_itemset):
return False
return True

frequent_itemsets['is_maximal'] =
frequent_itemsets['itemsets'].apply(lambda x:
is_maximal(set(x), frequent_itemsets))
```

2.5. Evaluasi dan Implementasi Rekomendasi

Rekomendasi produk berdasarkan *frequent maximal itemsets* diuji dengan menggunakan beberapa subset data yang berbeda. Produk yang kurang populer namun sering muncul dalam kombinasi transaksi dianalisis untuk memastikan relevansi rekomendasi. Evaluasi dilakukan berdasarkan nilai *support* dari item-item yang direkomendasikan, dengan fokus pada peningkatan visibilitas produk yang kurang terlihat sebelumnya.

Penelitian ini juga mengembangkan skrip Python untuk menemukan rekomendasi dari sebuah produk yang sedang dicari, sebagaimana berikut ini. SKU produk yang dicari dimasukkan ke dalam variabel "Produk_dicari".

Program Produk Hasil Rekomendasi

```
def buat_tabel_rekomendasi(produk_dicari,
maximal_itemsets, frequent_itemsets,
sku_to_product):
rows = []

# Pastikan produk_dicari berada dalam format
yang sama dengan SKU di DataFrame
produk_dicari = produk_dicari.strip() #
Menghapus spasi tambahan

# Temukan itemset maksimal yang mengandung
produk yang dicari
itemsets_with_produk_dicari =
maximal_itemsets[maximal_itemsets['itemsets']
.apply(lambda x: produk_dicari in x)]

for itemset in itemsets_with_produk_dicari['itemsets']:
# Temukan produk lain dalam itemset yang sama
other_products = [item for item in itemset
if item != produk_dicari]

# Tambahkan informasi produk lain ke dalam
tabel hasil
for product in other_products:
# Temukan support untuk produk tersebut
item_set = {product}
support_product =
frequent_itemsets[frequent_itemsets['itemsets']
].apply(lambda x:
item_set.issubset(x))['support'].values
if support_product.size > 0:
support_product = support_product[0]
else:
support_product = 0

rows.append({'Produk': produk_dicari, 'Rekomendasi Produk': product,
'Support': support_product})

# Membuat DataFrame hasil
df_rekomendasi = pd.DataFrame(rows)

# Menggabungkan dengan DataFrame
sku_to_product untuk mendapatkan nama produk
df_rekomendasi =
df_rekomendasi.merge(sku_to_product,
left_on='Rekomendasi Produk', right_on='SKU',
how='left')
df_rekomendasi.rename(columns={'Product
Name': 'Nama Produk'}, inplace=True)

return df_rekomendasi

# Produk yang dicari
produk_dicari = 'DCSVX3NKLY'

# Menjalankan fungsi untuk membuat tabel
rekomendasi
df_rekomendasi =
buat_tabel_rekomendasi(produk_dicari,
maximal_itemsets, frequent_itemsets,
sku_to_product)
```

2.6. Validasi Hasil Rekomendasi

Untuk memastikan efektivitas sistem rekomendasi yang dihasilkan melalui pendekatan *FMI*, dilakukan proses validasi terhadap pengguna vape. Proses validasi ini bertujuan untuk mengevaluasi seberapa efektif dan

akurat rekomendasi yang dihasilkan, terutama dalam memasukkan produk-produk dengan popularitas rendah (*long-tail*), dan untuk menganalisis hubungan konten antara produk-produk yang berasosiasi.

Metode pertama adalah **validasi pengguna**, dengan mendapatkan persetujuan langsung dari pengguna rokok elektronik mengenai keberadaan produk-produk dengan popularitas rendah dalam rekomendasi. Pengguna diminta untuk menilai sejauh mana mereka merasa bahwa produk-produk tersebut relevan dengan kebiasaan belanja mereka. Pendekatan ini dilakukan melalui survei yang disebarakan kepada sejumlah pengguna terpilih. Pertanyaan survei difokuskan pada dua aspek berikut:

- Pertanyaan 1 (P1: Relevansi): "Apakah menurut Anda produk rekomendasi ini relevan dengan produk utama yang sedang Anda cari?"; Dengan skala likert 1 menunjukkan Sangat Tidak Setuju sampai dengan 5 yang menunjukkan Sangat Setuju,
- Pertanyaan 2 (P2: Akan mencoba produk): "Apakah Anda akan mencoba juga produk rekomendasi ini ke depannya?"; Dengan skala likert 1 menunjukkan Sangat Tidak Mungkin sampai dengan 5 yang menunjukkan Sangat Mungkin,

Hasil survei ini diukur berdasarkan tingkat persetujuan pengguna terhadap rekomendasi yang menggabungkan produk populer dan *long-tail*. Skala likert digunakan untuk memudahkan kuantifikasi hasil, sehingga dapat dianalisis secara statistik apakah pengguna cenderung menyetujui atau menolak rekomendasi yang mencakup produk dengan popularitas rendah. Untuk survei ini, telah diambil sampel sebanyak 10 pengguna vape sebagai responden.

Selain dua pertanyaan di atas, **validasi juga diterapkan terhadap konten produk**, dimana pengguna juga dikonfirmasi melalui analisis konten antara produk-produk yang direkomendasikan bersama. Analisis ini bertujuan untuk melihat keterkaitan logis antara produk yang dihasilkan oleh algoritma *Frequent Maximal Itemset*. Misalnya, produk pod kit yang populer mungkin berasosiasi dengan berbagai cairan nikotin (*vape liquids*) dengan rasa dan kadar nikotin tertentu. Analisis konten melihat seberapa besar hubungan antara produk-produk ini, seperti:

- Kesamaan dalam kategori penggunaan (misalnya, perangkat vaping dengan cairan nikotin).
- Apakah produk-produk berpopularitas rendah memiliki hubungan yang jelas dan logis dengan produk yang lebih populer.
- Kesesuaian antara kegunaan produk dan kebiasaan konsumen.

Sebanyak tiga dari 10 responden disurvei lebih lanjut. Melalui analisis konten ini, dapat divalidasi apakah produk-produk *long-tail* yang direkomendasikan memang sesuai untuk digunakan bersamaan dengan produk populer, atau apakah hubungan antara produk ini hanya terjadi karena pola pembelian sebelumnya tanpa keterkaitan konten yang jelas.

3. Hasil dan Pembahasan

Penelitian ini menghasilkan beberapa temuan penting terkait penerapan algoritma Apriori dan *Frequent Maximal Itemset (FMI)* untuk meningkatkan visibilitas produk *long-tail* dalam sistem rekomendasi PT Mahakarya Distribusi. Hasil diuraikan dalam beberapa bagian yang mencakup analisis *frequent itemsets*, identifikasi *maximal itemsets*, dan evaluasi rekomendasi produk berdasarkan temuan tersebut.

3.1. Frequent Maximal Itemsets

Algoritma Apriori berhasil menemukan beberapa kombinasi produk (SKU) yang sering muncul bersama dalam transaksi. Proses ini melibatkan pengelompokan transaksi berdasarkan *Receipt Number* dan *Date*, lalu menjalankan Apriori untuk menemukan itemsets yang memenuhi ambang batas *support* minimum sebesar 0,001.

Tabel 1. Frequent Itemsets

<i>Itemset</i>	<i>Support</i>
SKU1, SKU2, SKU3, SKU4, SKU13, SKU21, SKU14, SKU45	0.318584
SKU5, SKU6, SKU7, SKU8, SKU44, SKU12, SKU43	0.002950
SKU9, SKU10, SKU11, SKU12, SKU34, SKU44, SKU55, SKU95	0.011799

Dari Tabel 1, terlihat bahwa beberapa itemset memiliki *support* yang tinggi (misalnya, SKU1 hingga SKU4), yang menunjukkan bahwa produk-produk ini sering dibeli bersama. Namun, itemset dengan *support* yang lebih rendah (SKU5 hingga SKU8) tetap dianggap signifikan, terutama dalam konteks produk *long-tail*. Ini menunjukkan bahwa produk dengan *support* rendah masih bisa memiliki relevansi dalam rekomendasi, terutama jika sering muncul bersama produk yang lebih populer.

Maximal Itemsets

Setelah frequent itemsets ditemukan, algoritma Apriori mengidentifikasi *frequent maximal itemsets*, yaitu kombinasi produk terbesar yang tidak bisa diperluas lebih lanjut tanpa menurunkan *support*-nya. Maximal itemsets ini lebih relevan dalam konteks rekomendasi

produk, terutama dalam strategi mempromosikan produk *long-tail* yang kurang populer.

Tabel 2. Frequent Maximal Itemsets


Itemset	Support
SKU1, SKU2, SKU3, SKU4, SKU5	0.002950
SKU6, SKU7, SKU8, SKU9	0.008850

Dari Tabel 2, terlihat bahwa beberapa *maximal itemsets* mengandung kombinasi produk yang tidak hanya mencakup produk populer tetapi juga produk yang kurang populer. Sebagai contoh, SKU5 adalah produk dengan *support* rendah, tetapi karena sering muncul bersama dengan SKU1 hingga SKU4 yang lebih populer, produk ini dapat diikutsertakan dalam rekomendasi, yang akan meningkatkan visibilitasnya.

Contoh Kasus: Jika konsumen membeli SKU1, SKU2, SKU3, dan SKU4, maka sistem akan merekomendasikan SKU5 karena produk ini sering muncul dalam kombinasi yang sama. Meskipun SKU5 memiliki *support* rendah secara individual, melalui analisis FMI, produk ini tetap muncul dalam rekomendasi, sehingga visibilitasnya meningkat.

3.2. Hasil Validasi Pengguna

Hasil validasi pengguna berdasarkan dua pertanyaan mengenai relevansi produk (P1) dan akan mencoba produk (P2) dijelaskan melalui chart dalam Gambar 2.



Gambar 2. Hasil Validasi Pengguna

Melalui *chart* diketahui bahwa atas, 90% pengguna menyatakan bahwa produk yang direkomendasikan relevan dengan produk utama yang mereka cari, dan 90% pengguna menyatakan mereka mungkin akan mencoba produk rekomendasi tersebut. Ini menunjukkan tingkat persetujuan yang tinggi, lebih dari 80%, yang menandakan sistem rekomendasi memiliki

potensi untuk memengaruhi keputusan pembelian pengguna.

Sebagai contoh (Tabel 3), ketika konsumen mencari produk “D Closed System Oxva Xlim Pro Pod Kit Black Gold (DCSOXPPKBG)”, sistem tidak hanya merekomendasikan pod kit tersebut, tetapi juga cairan nikotin seperti “L I Wise Happi Krunch Cereal Chocolate Milk Salt Nicotine 30ml 12mg Cukai (LIWHKCCMSN30ML12MGC)” dan “L I Majapahit Sparkling Pedia Mango Soju Pods Friendly 30ml 15mg Cukai (LIMSPMSPF30ML15MGC)”. Produk-produk ini mungkin memiliki *support* yang lebih rendah, namun karena sering dibeli bersama perangkat vaping, mereka tetap relevan untuk direkomendasikan.

Contoh lainnya, ketika produk “A Cartridge Oxva Xlim V2 0.8ohm (ACOXV20.8OHM)” dicari, produk cairan nikotin seperti “L I IDJ Una Strawberry Cheesecake 60ml 6mg Cukai (LIUSC60ML6MGC)” dengan *support* 0.002950 dan “L I Foom Yellow Gummy Salt Nicotine 30ml 30mg Cukai (LIFYGSN30ML30MGC)” dengan *support* 0.005900 muncul sebagai rekomendasi. Produk-produk ini sering dibeli bersama perangkat vaping, sehingga meskipun frekuensi pembeliannya rendah, mereka tetap relevan dan berpotensi meningkatkan penjualan.

Tabel 3. Contoh Rekomendasi Produk Berdasarkan Itemset

Produk Dicari	Rekomendasi Produk	Support
DCSOXPPKBG	LIWHKCCMSN30ML12MGC	[0.002950, 0.014749,
	LIDJMHSMIPF30ML15MGC, ACUCG0.8OHM, LIMSPMSPF30ML15MGC	0.120944, 0.005900]
ACOXV20.8OHM	LIFPSBSN30ML30MGC, LIUSC60ML6MGC, LIFYGSN30ML30MGC, DCSOXPPKGG	[0.005900, 0.002950, 0.005900, 0.002950]
	LIEMICR60ML3MGC, ACOXV20.8OHM, LIFSTLSN30ML30MGC, DCSOXV2PK900MAHSB, ACUCG0.8OHM, ACMACDCB	[0.005900, 0.073746, 0.017699, 0.008850, 0.120944, 0.079646]

3.3. Hasil Validasi Konten

Rekomendasi item melalui maximal itemset yang dihasilkan juga menunjukkan keterhubungan antara items di dalam maximal itemset tersebut. Sebanyak tiga dari 10 responden menjelaskan keterhubungan yang logis antara produk perangkat vaping dan cairan nikotin. Dalam dunia vaping, perangkat seperti pod kit atau cartridge sangat tergantung pada cairan nikotin untuk dapat digunakan. Hubungan ini menjadi dasar dari

rekomendasi produk cairan nikotin bersama perangkat vaping meskipun *support* dari produk cairan tersebut mungkin rendah.

Pendekatan ini memperlihatkan kemampuan algoritma *Frequent Maximal Itemset* dalam mengidentifikasi produk *long-tail* yang jarang dibeli secara individu, namun sering dibeli bersama produk populer, yang memungkinkan peningkatan visibilitas produk-produk ini. Pendekatan FMI memungkinkan produk-produk *long-tail* seperti cairan nikotin dengan berbagai varian rasa dan kadar nikotin untuk direkomendasikan bersama produk yang lebih populer. Meskipun produk ini mungkin memiliki *support* rendah, mereka tetap relevan karena sering kali dibeli bersama produk populer seperti pod kit. Hal ini membuka peluang bagi produk-produk yang sebelumnya kurang terekspos untuk mendapatkan visibilitas lebih besar, sehingga meningkatkan potensi penjualannya.

Perbandingan dengan Collaborative-Filtering

Collaborative Filtering adalah salah satu metode rekomendasi yang paling umum digunakan, terutama karena kemampuannya dalam mempersonalisasi rekomendasi berdasarkan riwayat interaksi pengguna. Metode ini bekerja dengan mengidentifikasi pola pembelian pengguna dan mencocokkan mereka dengan pola pengguna lain yang serupa. Namun, dalam konteks produk *long-tail*, metode ini menghadapi beberapa tantangan signifikan yang mempengaruhi efektivitasnya.

Salah satu keterbatasan utama Collaborative Filtering adalah ketergantungannya pada riwayat interaksi pengguna. Untuk menghasilkan rekomendasi yang akurat, metode ini memerlukan data interaksi seperti login atau riwayat pembelian pengguna. Dalam platform yang memiliki banyak pengguna anonim atau baru, seperti toko online VAPE yang dianalisis dalam penelitian ini, Collaborative Filtering menjadi kurang efektif. Hal ini karena tidak adanya data riwayat yang cukup untuk memberikan rekomendasi yang relevan, sehingga rekomendasi untuk produk *long-tail* menjadi lebih sulit dicapai.

Selain itu, Collaborative Filtering cenderung memiliki bias terhadap produk-produk populer. Produk yang sering dibeli oleh banyak pengguna cenderung lebih sering direkomendasikan, sementara produk *long-tail* yang kurang populer atau jarang muncul dalam riwayat pembelian pengguna sering diabaikan. Misalnya, ketika mayoritas pengguna membeli produk pod kit yang populer, Collaborative Filtering akan lebih sering merekomendasikan produk serupa, sedangkan produk *long-tail* seperti cairan nikotin dengan varian rasa unik atau kadar nikotin yang lebih tinggi mungkin tidak akan muncul dalam rekomendasi. Akibatnya, produk *long-*

tail seringkali kehilangan visibilitas dalam sistem rekomendasi berbasis Collaborative Filtering.

Sebaliknya, Frequent Maximal Itemset yang diterapkan dalam penelitian ini menawarkan beberapa keunggulan dalam mengatasi masalah yang dihadapi oleh Collaborative Filtering. Salah satu keunggulan utama FMI adalah bahwa pendekatan ini tidak memerlukan data pengguna sama sekali. FMI hanya mengandalkan pola transaksi sebelumnya, tanpa perlu mengetahui preferensi individu atau riwayat pembelian pengguna. Hal ini membuat FMI lebih fleksibel dan efektif dalam situasi di mana pengguna tidak memiliki riwayat interaksi atau login, seperti di platform dengan banyak pengguna anonim.

Selain itu, FMI memungkinkan produk *long-tail* yang kurang populer tetap direkomendasikan bersama produk yang lebih populer dalam *itemsets* yang lebih besar. Misalnya, meskipun sebuah produk cairan nikotin tertentu memiliki *support* yang rendah, produk tersebut tetap dapat muncul dalam rekomendasi karena sering dibeli bersama perangkat vaping yang lebih populer. Dengan demikian, FMI membantu meningkatkan visibilitas produk *long-tail* dan mengatasi bias terhadap produk populer yang ada dalam Collaborative Filtering.

Secara keseluruhan, pendekatan FMI terbukti lebih fleksibel dan efektif dalam meningkatkan visibilitas produk *long-tail* di toko online VAPE. Sementara Collaborative Filtering cenderung mengutamakan produk-produk populer dan memerlukan data pengguna, FMI dapat menyeimbangkan rekomendasi produk populer dan *long-tail* tanpa memerlukan data pengguna. Pendekatan ini lebih sesuai dalam konteks platform dengan pengguna anonim atau baru, serta lebih optimal dalam mendorong penjualan produk *long-tail* yang seringkali terabaikan dalam sistem rekomendasi berbasis popularitas.

4. Kesimpulan

Penelitian ini menunjukkan bahwa pendekatan Frequent FMI efektif dalam meningkatkan visibilitas produk *long-tail* di toko online rokok elektronik (vape). Melalui analisis pola pembelian, FMI berhasil mengidentifikasi dan merekomendasikan produk *long-tail* yang kurang populer namun relevan, terutama dalam hubungannya dengan produk-produk populer yang sering dibeli bersamaan. Hasil validasi dari 10 pengguna menunjukkan bahwa 90% responden merasa bahwa rekomendasi yang diberikan relevan dengan produk utama yang mereka cari. Hal ini menunjukkan bahwa produk *long-tail* yang muncul dalam rekomendasi masih dianggap relevan oleh pengguna meskipun memiliki *support* rendah. Selain itu, 90% pengguna juga menyatakan kemungkinan besar mereka akan mencoba produk yang direkomendasikan di masa depan, yang mengindikasikan potensi adopsi yang tinggi untuk

produk-produk *long-tail* yang jarang terekspos dalam sistem rekomendasi tradisional. Validasi yang dilakukan juga menunjukkan bahwa produk *long-tail* yang direkomendasikan bersamaan dengan produk populer memiliki keterkaitan logis dalam konteks penggunaan, seperti cairan nikotin dan perangkat vaping. Hal ini menegaskan bahwa rekomendasi produk *long-tail* tidak hanya relevan secara kuantitatif (berdasarkan pola transaksi), tetapi juga memiliki kesesuaian konten dengan produk utama yang sedang dicari pengguna.

Daftar Rujukan

- [1] Y. Liu, X. Zhang, M. Zou, and Z. Feng, "Co-occurrence Embedding Enhancement for Long-tail Problem in Multi-Interest Recommendation," in *Proceedings of the 17th ACM Conference on Recommender Systems, RecSys 2023*, 2023. doi: 10.1145/3604915.3608835.
- [2] E. Malekzadeh Hamedani and M. Kaedi, "Recommending the long tail items through personalized diversification," *Knowledge-Based Syst.*, vol. 164, 2019, doi: 10.1016/j.knosys.2018.11.004.
- [3] M. Pandharkar and P. Raoundale, "A Systematic Study of Approaches used to Address the Long Tail Problem," in *Proceedings of the 17th INDIACom; 2023 10th International Conference on Computing for Sustainable Global Development, INDIACom 2023*, 2023.
- [4] M. A. Hart, "The Long Tail: Why the Future of Business Is Selling Less of More by Chris Anderson," *J. Prod. Innov. Manag.*, vol. 24, no. 3, 2007, doi: 10.1111/j.1540-5885.2007.00250.x.
- [5] W. He, D. Ai, and C. Wu, "A recommender model based on strong and weak social Ties: A Long-tail distribution perspective," *Expert Syst. Appl.*, vol. 184, 2021, doi: 10.1016/j.eswa.2021.115483.
- [6] T. Yu, J. Guo, W. Li, H. J. Wang, and L. Fan, "Recommendation with diversity: An adaptive trust-aware model," *Decis. Support Syst.*, vol. 123, 2019, doi: 10.1016/j.dss.2019.113073.
- [7] T. A. Armanda, I. P. Wardhani, T. M. Akhriza, and T. M. A. Admira, "Recurrent Session Approach to Generative Association Rule based Recommendation," *Knowl. Eng. Data Sci.*, vol. 6, no. 2, pp. 199–214, 2023, [Online]. Available: <http://repo.stimata.ac.id/id/eprint/376/>
- [8] L. D. Adistia, T. M. Akhriza, and S. Jatmiko, "Sistem Rekomendasi Buku untuk Perpustakaan Perguruan Tinggi Berbasis Association Rule," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 2, 2019, doi: 10.29207/resti.v3i2.971.
- [9] T. M. Akhriza and D. S. Utsalina, "STIMATA Rule Adviser: Sistem Rekomendasi Produk e-Commerce," in *IAII SISFOTEK VII*, 2023.
- [10] M. Husni, T. M. Akhriza, S. Madenda, and E. P. Wibowo, "Improving Recentness of the ICT Book Recommendation using an Adaptive Rules-based Recommender System," *Int. J. Comput. Appl. Technol.*, vol. (In Press), 2022.
- [11] Latifah, T. M. Akhriza, and L. D. Adistia, "Constructing Recommendation about Skills Combinations Frequently Sought in IT Industries Based on Apriori Algorithm," *Adv. Comput. Sci. Res.*, vol. 95, Jan. 2020, doi: 10.2991/miseic-19.2019.12.
- [12] T. M. Akhriza, Y. Ma, and J. Li, "Revealing the Gap Between Skills of Students and the Evolving Skills Required by the Industry of Information and Communication Technology," *Int. J. Softw. Eng. Knowl. Eng.*, vol. 27, no. 05, pp. 675–698, 2017, doi: 10.1142/s0218194017500255.
- [13] T. M. Akhriza and I. D. Mumpuni, "Quantitative class association rule-based approach to lecturer career promotion recommendation," *Int. J. Inf. Decis. Sci.*, vol. 13, no. 2, 2021.