

ANALISIS POLA PEMBELIAN KONSUMEN MENGGUNAKAN ALGORITMA ASSOCIATION RULES PADA AHASS

Handrik Gustapo¹, Anggia Dasa Putri²

¹Program Studi Teknik Informatika, Universitas Putera Batam

²Program Studi Teknik Informatika, Universitas Putera Batam

email: pb210210022@upbatam.ac.id

ABSTRACT

Consumer purchasing pattern analysis is a strategic approach to understanding customer behavior and supporting data-driven decision-making. This research was conducted at AHAS PT. Mitra Pinasthika Mustika Batam with the aim of identifying relationships between motorcycle service items that are frequently selected together by consumers. The method used is the Association Rules algorithm, specifically Apriori, with a quantitative approach applied to 4,026 transaction records from April to June 2025. The data were analyzed through preprocessing, one-hot encoding, and the application of the Apriori algorithm using parameters of minimum support of 5%, confidence of 30%, and lift > 1. The results showed 80 frequent itemsets and 38 valid association rules. The rule with the highest lift was Oil Chang)-Gear Set, indicating a strong correlation between the two services. Other patterns such as Sporing → Front Tire and Air Filter Balancing also showed significant associations. These findings can be utilized to design service bundling strategies, automatic recommendation systems, and optimize stock and workforce management. This study proves that the Apriori algorithm is effective in uncovering hidden patterns within transaction data, enhancing operational efficiency and service quality in the automotive sector.

Keywords: Apriori, Association Rules, Purchase Patterns, AHAS

PENDAHULUAN

Pola pembelian konsumen merupakan aspek krusial dalam pengambilan keputusan bisnis, terutama dalam hal pengelolaan persediaan, perancangan promosi, dan pengembangan strategi pemasaran. Di era persaingan yang semakin kompetitif, perusahaan dituntut untuk mampu memanfaatkan data historis secara maksimal guna menciptakan keunggulan kompetitif dan meningkatkan kepuasan pelanggan (Noviyanti & Juanita, 2024). Namun, volume dan kompleksitas data transaksi

yang besar sering kali menjadi kendala dalam proses analisis manual, sehingga diperlukan pendekatan analitik yang sistematis dan efisien (Widodo et al., 2021).

PT. Mitra Pinasthika Mustika Batam, sebagai penyedia layanan Astra Honda Authorized Service Station (AHAS), melayani ribuan konsumen setiap bulan melalui pembelian suku cadang, pelumas, serta layanan servis berkala maupun insidental. Meski data transaksi telah terkumpul dalam jumlah besar, pemanfaatannya masih terbatas pada

aspek administratif. Padahal, informasi tersebut memiliki potensi besar dalam mengungkap keterkaitan antar item produk maupun layanan yang sering muncul bersama dalam satu transaksi.

Penerapan algoritma *association rules*, khususnya algoritma *Apriori*, menjadi salah satu solusi yang relevan dalam menganalisis pola pembelian konsumen. Algoritma ini banyak digunakan dalam *market basket analysis* untuk mengidentifikasi *frequent itemsets* serta menghasilkan aturan asosiasi berdasarkan nilai *support* dan *confidence* (Merliani et al., 2022, Vidiya & Testiana, 2023, Prasetya et al., 2022). Dengan algoritma ini, perusahaan dapat merancang strategi bundling produk, mengoptimalkan manajemen persediaan, serta meningkatkan efisiensi layanan secara *data-driven*.


Penelitian ini difokuskan pada analisis pola pembelian suku cadang dan layanan servis di AHAS PT. Mitra Pinasthika Mustika Batam. Metode yang digunakan adalah algoritma *Apriori* dengan implementasi menggunakan Python dan Weka. Penelitian ini bertujuan untuk mengidentifikasi kombinasi item yang sering muncul bersama dalam satu transaksi dan menyajikan hasil analisis tersebut sebagai dasar pengambilan keputusan yang lebih efektif di bidang manajemen stok

KAJIAN TEORI

2.1 Knowledge Discovery in Databases

Knowledge Discovery in Databases (KDD) adalah proses sistematis untuk menggali pengetahuan tersembunyi dari data besar melalui beberapa tahapan, yaitu: seleksi data, pra-proses, transformasi, data mining, dan evaluasi hasil (Anggrawan et al., 2021). Dalam penelitian ini, KDD digunakan sebagai

kerangka kerja untuk mengolah data transaksi konsumen, dengan fokus pada penerapan algoritma *Apriori* dalam tahap data mining guna menemukan pola keterkaitan antar item (Tarigan et al., 2022).




Gambar 1. Knowledge Discovery in Database

(Sumber: Data Penelitian., 2025)

2.2 Data Mining

Data mining merupakan inti dari proses *Knowledge Discovery in Databases* (KDD) yang bertujuan untuk menemukan pola atau hubungan tersembunyi dalam data berskala besar melalui pendekatan statistik dan algoritma analitik (Anggrawan et al., 2021). Dalam konteks bisnis, data mining membantu memahami perilaku konsumen dan menyusun strategi pemasaran yang lebih tepat sasaran (Ndoya & Putri, 2024).



Gambar 2. Tahapan Data Mining

(Sumber: Data Penelitian., 2025)

2.3 Algoritma Association Rules

Association rules adalah metode dalam data mining yang digunakan untuk menemukan hubungan antar item dalam kumpulan data, khususnya dalam analisis pola belanja konsumen atau *market basket analysis* (Merliani et al., 2022). Teknik ini menghasilkan aturan dalam bentuk implikasi “jika A maka B” untuk mengidentifikasi produk yang sering dibeli secara bersamaan.

2.4 Algoritma Apriori

Algoritma Apriori adalah metode populer dalam *association rule mining* untuk menemukan keterkaitan antar item dalam data transaksi. Tujuan utamanya adalah mengidentifikasi *frequent itemsets* kombinasi item yang sering muncul bersama dan membentuk aturan asosiasi berdasarkan ambang *support* dan *confidence* tertentu (Prasetya et al., 2021; Vidiya & Testiana, 2023).


2.5 Pola Pembelian Konsumen

Pola pembelian konsumen mencerminkan kebiasaan sistematis dalam membeli produk, baik dilihat dari frekuensi, kombinasi barang yang dibeli bersamaan, maupun preferensi terhadap kategori produk tertentu. Analisis pola ini penting dalam dunia bisnis karena dapat memberikan wawasan strategis untuk mengelola stok, promosi, dan tata letak produk secara lebih efisien (Juliadi et al., 2024). Dengan pendekatan data mining seperti algoritma *Association Rules*, item yang sering muncul bersama dalam satu transaksi dapat diidentifikasi dan dirumuskan sebagai aturan asosiasi, seperti “jika membeli oli mesin, maka juga membeli busi” (Vidiya & Testiana, 2023).

Pada penelitian ini, peneliti menggunakan *Google Colaboratory* (Colab) yang merupakan *platform* pemrograman berbasis *cloud* dari Google yang memungkinkan pengguna menjalankan kode Python langsung dari browser tanpa konfigurasi lokal. Colab terintegrasi dengan pustaka populer seperti NumPy, pandas, dan scikit-learn, serta mendukung pemrosesan menggunakan GPU secara gratis. (Prasetya et al., 2021; Putra et al., 2023; Vidiya & Testiana, 2023)

METODE PENELITIAN

Desain penelitian yang digunakan dalam penelitian ini digambarkan oleh *flowchart* di bawah ini.



Gambar 3. Desain Penelitian
(Sumber: Data Penelitian, 2025)

Penelitian ini dimulai dengan identifikasi dan perumusan masalah untuk menguraikan isu utama terkait pemanfaatan data transaksi konsumen, dilanjutkan dengan analisis mendalam

terhadap dampaknya pada proses bisnis AHHAS. Kajian literatur dilakukan guna memahami teori algoritma *Association Rules*, khususnya *Apriori*, sebagai dasar metodologi. Data dikumpulkan melalui observasi, wawancara, dan dokumentasi transaksi periode Mei–Juni 2025. Selanjutnya, data diolah menggunakan algoritma *Apriori* di *Google Colaboratory* dengan *Python* untuk menemukan *frequent itemset* dan asosiasi antar produk. Tahap akhir mencakup evaluasi hasil menggunakan metrik seperti *support*, *confidence*, dan *lift*, serta visualisasi untuk memastikan bahwa pola yang ditemukan relevan secara statistik dan bermakna.

3.1 Metode Pengumpulan Data

Data dalam penelitian ini diperoleh melalui dua metode, yaitu data sekunder berupa dataset transaksi pelanggan AHHAS PT. Mitra Pinasthika Mustika Batam periode Mei–Juni 2025, dan data primer melalui wawancara semi-terstruktur dengan kepala bengkel. Dataset mencakup informasi item pembelian, layanan, waktu transaksi, serta pendapatan. Wawancara digunakan untuk melengkapi pemahaman terkait alur transaksi, layanan populer, dan strategi pengelolaan stok maupun promosi.


3.2 Populasi dan Sampel

Populasi dalam penelitian ini mencakup seluruh transaksi pembelian suku cadang dan layanan servis kendaraan di AHHAS PT. Mitra Pinasthika Mustika Batam selama Mei hingga Juni 2025, dengan total sekitar 4.026 transaksi. Sampel diambil menggunakan teknik *simple random sampling* sebagai bagian dari *probability sampling*, di mana setiap transaksi

memiliki peluang yang sama untuk terpilih. Penentuan jumlah sampel dilakukan dengan rumus Slovin menggunakan tingkat kesalahan 10%, sehingga diperoleh 98 transaksi sebagai sampel yang mewakili populasi, yang selanjutnya digunakan untuk analisis lebih lanjut.

3.3 Metode Perancangan

Penelitian ini menggunakan pendekatan *data mining* dengan algoritma *Association Rules*, khususnya metode *Apriori*, untuk mengidentifikasi keterkaitan antar item dalam data transaksi pelanggan AHHAS.



Gambar 4. Metode Perancangan
(Sumber: Data Penelitian, 2025)

Proses perancangan meliputi empat tahap utama, yaitu pra-pemrosesan data, transformasi data, penerapan algoritma *Apriori*, dan pembentukan aturan asosiasi. Tahap pra-pemrosesan mencakup pembersihan data, standarisasi format item, serta tokenisasi transaksi agar sesuai dengan struktur yang dibutuhkan. Data yang telah diproses kemudian ditransformasikan menjadi format biner menggunakan *TransactionEncoder*, menghasilkan

```

Julai total data (paginasi): 4026
Julai sampel (dengan margin of error 10k): 98

Contoh data hasil sampling:
transactionID Tanggal Jamtransaksi JumlahKendaraan \
2401 13177 2023-05-06 15:15 10
2402 11776 2023-05-13 16:30 4
2382 13360 2023-05-10 10:30 7
2066 13044 2023-05-01 10:00 8
999 11777 2023-05-16 15:30 3

Item
PendapatanJasa
2401 Kanvas Rem, Servis CV 45000
798 Kanvas Rem, Filter udara, Ganti Oli, Ganti Aki... 110000
2382 Kabel Gas, Filter udara, Tune up 50000
2066 Lampu Belakang, Aki, Ganti Busi 30000
999 Kanvas Rem, Busi, Lampu Belakang, Kantai, Lamp... 10000

PendapatanParti PendapatanIkon098 PendapatanIkon099 TotalGaji
2401 45000 0 45000
798 65000 0 65000
2382 50000 0 50000
2066 35000 0 35000
999 240000 0 270000

Clocking
2401 0.5
798 1.3
2382 0.5
2066 0.1
999 1

```

```
import pandas as pd
import math

# 1. Baca file CSV yang sudah ada di file system
df = pd.read_csv("content/transaksi_abbas_final_mai_juni2025.csv")

# 2. Hitung Jumlah populasi
N = len(df)
print(f"Jumlah total data (populasi): {N}")

# 3. Hitung Jumlah sampel dengan rumus Slovin (e = 10%)
e = 0.10
N = N / (1 + N * e**2)
n = round(N)
print(f"Jumlah sampel (dengan margin of error 10%): {n}")

# 4. Ambil sample acak tanpa pengembalian
df_sample = df.sample(n=n, random_state=42)

# 5. Tampilkan beberapa baris data hasil sampling
print("\nContoh data hasil sampling:")
print(df_sample.head())

# 6. Simpan ke file CSV (bukan Excel)
df_sample.to_csv("data_sampelan.csv", index=False)

# 7. (Optional) Download file
from google.colab import files
files.download("data_sampelan.csv")
```

34

```
import pandas as pd

# 1. Baca file hasil sampling (pastikan file ini sudah ada di file explorer Colab)
df = pd.read_csv("data_sampled.csv")

# 2. Pembersihan Data: hapus duplikat dan nilai kosong pada kolom penting
df = df.drop_duplicates()
df = df.dropna(subset=["Items", "Tanggal", "TotalHarga"])

# 3. Standarisasi Format: rapikan penulisan di kolom Items
def clean_items(text):
    # Normalisasi: kapitalisasi, hapus spasi ekstra
    items = [item.strip().title() for item in str(text).split(",")]
    return ", ".join(items)

df["Items"] = df["Items"].apply(clean_items)

# 4. Tokenisasi Transaksi: ubah menjadi list item
df["ItemList"] = df["Items"].apply(lambda x: [item.strip() for item in x.split(",")])

# 5. Simpan hasil pra-pemrosesan ke dalam file CSV dan Excel
df.to_csv("data_pra_proses.csv", index=False)
df.to_excel("data_pra_proses.xlsx", index=False)

# 6. Lihat hasil pra-pemrosesan
df[["Items", "ItemList"]].head()
```

Gambar 7. Kode Bagian Pra-Pemrosesan Data
(Sumber: Data Penelitian, 2025)

Index	Items	Transaksi
0	Kampus Rem, Servis Cvt	Kampus Rem, Servis Cvt
1	Kampus Rem, Filter Udara, Ganti Oli, Ganti Aki, Balancing, Servis Ringan	Kampus Rem, Filter Udara, Ganti Oli, Ganti Aki, Balancing, Servis Ringan
2	Kahat Gas, Filter Udara, Tune Up	Kahat Gas, Filter Udara, Tune Up
3	Lampu Belakang, Aki, Ganti Ban	Lampu Belakang, Aki, Ganti Ban
4	Kampus Rem, Busi, Lampu Belakang, Rantai, Lampu Depan, Servis Ringan	Kampus Rem, Busi, Lampu Belakang, Rantai, Lampu Depan, Servis Ringan

Gambar 8. Sampel Luaran Kode Pra-Pemrosesan Data
(Sumber: Data Penelitian, 2025)

Hasil dari tahapan pra-pemrosesan mencakup penghapusan data duplikat dan penanganan nilai kosong pada kolom penting seperti *Items*, *Tanggal*, dan *TotalHarga* guna menjaga integritas data. Dilanjutkan dengan standarisasi penulisan pada kolom *Items* untuk menghindari inkonsistensi, serta tokenisasi transaksi yang mengubah string menjadi list item individual agar sesuai format masukan algoritma *Apriori*.

4.2 Hasil Transformasi Data

Setelah pra-pemrosesan, data ditransformasikan ke bentuk biner menggunakan *TransactionEncoder* dari pustaka *mlxtend.preprocessing*. Proses ini mengubah setiap transaksi berbentuk list item menjadi tabel *boolean*, yaitu baris merepresentasikan transaksi dan kolom menunjukkan item unik. Nilai *True* menandakan item hadir dalam transaksi, sedangkan *False* menunjukkan

sebaliknya. Format ini diperlukan untuk mendukung proses analisis asosiasi menggunakan algoritma *Apriori* secara optimal.

```
# 1. Import pustaka
import pandas as pd
from mlxtend.preprocessing import TransactionEncoder
from google.colab import files

# 2. Baca file hasil pra-pemrosesan
df = pd.read_csv("data_pra_proses.csv")

# 3. Ambil data transaksi (list of items per transaksi)
transactions = df["ItemList"].tolist() # eval untuk mengubah string ke list

# 4. Inisialisasi TransactionEncoder dan lakukan transformasi
te = TransactionEncoder()
te_ary = te.fit(transactions).transform(transactions)

# 5. Konversi hasil transformasi ke DataFrame biner
df_transformed = pd.DataFrame(te_ary, columns=te.columns_)

# 6. Tampilkan hasil awal
print("Contoh hasil transformasi:")
print(df_transformed.head())

# 7. Simpan hasil transformasi ke file CSV dan Excel
df_transformed.to_csv("data_transformed.csv", index=False)
df_transformed.to_excel("data_transformed.xlsx", index=False)
```

Gambar 9. Kode Bagian Transformasi Data
(Sumber: Data Penelitian, 2025)

Contoh hasil transformasi:

	Aki	Balancing	Ban Belakang	Ban Depan	Busi	Cek Rem	Filter Udara	Udara
0	False	False	False	False	False	False	False	False
1	False	True	False	False	False	False	False	True
2	False	False	False	False	False	False	False	True
3	True	False	False	False	False	False	False	False
4	False	False	False	False	True	False	False	False

	Ganti Aki	Ganti Ban	Ganti Busi	...	Kampus Rem	Lampu Belakang	...
0	False	False	False	...	True	False	...
1	True	False	False	...	True	False	...
2	False	False	False	...	False	False	...
3	False	False	True	...	False	True	...
4	False	False	False	...	True	True	...

	Lampu Depan	Oli Mesin	Rantai	Servis Cvt	Servis Lengkap	Servis Ringan	...
0	False	False	False	True	False	False	...
1	False	False	False	False	False	True	...
2	False	False	False	False	False	False	...
3	False	False	False	False	False	False	...
4	True	False	True	False	False	True	...

	Spooring	Tune Up
0	False	False
1	False	False
2	False	True
3	False	False
4	False	False

[5 rows x 23 columns]

Gambar 10. Sampel Data yang Telah Ditransformasi
(Sumber: Data Penelitian, 2025)

Berdasarkan Gambar di atas, menampilkan sebagian hasil transformasi yang menunjukkan lima transaksi pertama dan 23 kolom item unik yang teridentifikasi. Menggunakan format ini, data menjadi lebih mudah untuk dianalisis menggunakan algoritma *apriori* dalam proses pencarian frequent itemset dan pembentukan aturan asosiasi.

4.3 Hasil Frequent Itemsets

Setelah transformasi data ke format *one-hot encoded* berbasis *boolean*, algoritma *Apriori* diterapkan untuk mengidentifikasi *frequent itemsets*, yakni kombinasi item yang sering muncul bersama dalam transaksi. Dalam representasi ini, nilai *True* menandakan kehadiran suatu item dalam transaksi. Proses ini dilakukan menggunakan fungsi *apriori* dari pustaka *mlxtend.frequent_patterns*, dengan ambang *minimum support* sebesar 0.05. Artinya, hanya kombinasi item yang muncul di minimal 5 dari 98 transaksi (5%) yang dipertimbangkan dalam analisis lebih lanjut.

```
# 1. Import pustaka
import pandas as pd
from mlxtend.frequent_patterns import apriori

# 2. Baca data hasil transformasi (one-hot encoded)
df_transformed = pd.read_csv("data_transformed.csv")

# 3. Tetapkan nilai minimum support
min_support = 0.05 # 5% dari 98 transaksi = min 5 transaksi

# 4. Jalankan algoritma Apriori
frequent_itemsets = apriori(df_transformed, min_support=min_support, use_colnames=True)

# 5. Tambahkan kolom 'length' untuk melihat jumlah item dalam kombinasi
frequent_itemsets['length'] = frequent_itemsets['itemsets'].apply(lambda x: len(x))


# 6. Tampilkan hasil frequent itemsets
print("Frequent itemsets:")
print(frequent_itemsets.sort_values(by="support", ascending=False).head())

# 7. Simpan hasil ke file
frequent_itemsets.to_csv("frequent_itemsets.csv", index=False)
frequent_itemsets.to_excel("frequent_itemsets.xlsx", index=False)
```

Gambar 11 Kode Bagian Frequent Itemset

(Sumber: Data Penelitian, 2025)

Frequent itemsets:		
	support	itemsets length
11	0.275510	(Gear Set) 1
8	0.255102	(Ganti Ban) 1
14	0.244898	(Lampu Belakang) 1
1	0.234694	(Balancing) 1
19	0.234694	(Servis Lengkap) 1
2	0.214286	(Ban Belakang) 1
13	0.214286	(Kampas Rem) 1
3	0.214286	(Ban Depan) 1
9	0.204082	(Ganti Busi) 1
16	0.204082	(Oli Mesin) 1



Gambar 12. Sampel Luaran Frequent Itemsets

(Sumber: Data Penelitian, 2025)

Berdasarkan gambar di atas, diperoleh 10 *frequent itemsets* dengan nilai *support* tertinggi. Item *Gear Set* menunjukkan nilai tertinggi sebesar 0,2755 (27,55% dari total transaksi), diikuti oleh *Ganti Ban* (25,51%) dan *Lampu Belakang* (24,49%). Item lain seperti *Balancing*, *Servis Lengkap*, dan *Ban Belakang* juga memiliki tingkat kemunculan signifikan, masing-masing melebihi 20%.

Algoritma *Apriori* berhasil mengidentifikasi 80 kombinasi item dengan minimum support 0,05, mencakup item tunggal hingga gabungan yang sering muncul bersama dalam transaksi. Temuan ini menunjukkan pola pembelian berulang yang dapat dimanfaatkan untuk strategi paket layanan, promosi, dan perencanaan stok. Pola ini juga menjadi dasar pembentukan *association rules* selanjutnya.

4.4 Hasil Pembentukan Aturan Asosiasi

Setelah menghasilkan 80 kombinasi item (*frequent itemsets*) pada tahap sebelumnya, langkah selanjutnya adalah membentuk aturan asosiasi (*association rules*) menggunakan metode *confidence* dan *lift*. Aturan asosiasi ini berguna untuk mengidentifikasi hubungan antar item yang sering muncul bersama dalam satu

```
# 1. Import fungsi association_rules
from mlxtand.frequent_patterns import association_rules

# 2. Mengitung aturan asosiasi dari frequent itemsets
rules = association_rules(frequent_itemsets, metric='confidence', min_threshold=0.3)


# 3. Filter aturan berdasarkan threshold support, confidence, dan lift
rules_filtered = rules[
    (rules['support'] >= 0.05) &
    (rules['confidence'] >= 0.3) &
    (rules['lift'] > 1.0)
].copy()

# 4. Urutkan berdasarkan nilai lift tertinggi
rules_filtered = rules_filtered.sort_values(by='lift', ascending=False)

# 5. Tampilkan beberapa aturan teratas
print("Aturan asosiasi yang memenuhi kriteria:")
print(rules_filtered['antecedents', 'consequents', 'support', 'confidence', 'lift'].head(10))

# 6. Simpan hasil ke file
rules_filtered.to_csv("association_rules_filtered.csv", index=False)
rules_filtered.to_excel("association_rules_filtered.xlsx", index=False)
```

Aturan asosiasi yang memenuhi kriteria:					
	antecedents	consequents	support	confidence lift	
30	(Ganti Oli)	(Gres Set)	0.071429	0.700000	2.540741
32	(Springs)	(Beda Set)	0.061224	0.461538	1.253846
3	(Servis Ringan)	(Kampas Rem)	0.051020	0.416667	1.944444
35	(Filter Udara)	(Balancing)	0.081633	0.444444	1.893720
2	(Balancing)	(Filter Udara)	0.081633	0.347826	1.893720
20	(Filter Udara)	(Kabel Gas)	0.061224	0.333333	1.814815
21	(Kabel Gas)	(Filter Udara)	0.061224	0.333333	1.814815
17	(Cek Rem)	(Kabel Gas)	0.061224	0.333333	1.814815
16	(Kabel Gas)	(Cek Rem)	0.061224	0.333333	1.814815
5	(Busi)	(Ban Belakang)	0.051020	0.384615	1.794872



Tahap pembentukan aturan asosiasi dilakukan menggunakan fungsi `association_rules` dari pustaka `mlxtend`, dengan parameter minimum *confidence* sebesar 0,3, *support* minimal 0,05, serta filter *lift* > 1. Kombinasi parameter ini bertujuan untuk menghasilkan aturan yang signifikan secara statistik dan bermakna secara bisnis. Dari proses ini, diperoleh 38 aturan asosiasi yang memenuhi seluruh kriteria.

Gambar di bawah ini menampilkan 10 aturan asosiasi dengan nilai *lift* tertinggi, yang menunjukkan kekuatan hubungan antara kombinasi item dalam transaksi. Aturan dengan nilai *lift* tertinggi adalah *Ganti Oli* $\rightarrow$ *Gear Set*, dengan *lift* mendekati 2,5, mengindikasikan bahwa pelanggan yang melakukan *Ganti Oli* memiliki kecenderungan kuat untuk juga melakukan penggantian *Gear Set*. Aturan lain seperti *Sporing* $\rightarrow$ *Ban Depan* dan *Servis Ringan* $\rightarrow$ *Kampas Rem* juga memperlihatkan korelasi yang erat.

Berdasarkan Gambar 14, diperoleh sepuluh aturan asosiasi teratas berdasarkan nilai *lift*, yang merepresentasikan kekuatan hubungan antara kombinasi item dalam transaksi. Aturan dengan *lift* tertinggi adalah *Ganti Oli* → *Gear Set*, dengan nilai mendekati 2,5, menunjukkan bahwa kedua layanan tersebut cenderung muncul bersamaan 2,5 kali lebih sering dibandingkan kemunculan acak. Aturan lainnya seperti *Spooing* → *Ban Depan* dan *Servis Ringan* → *Kampas Rem* juga menunjukkan korelasi yang kuat.

Kemunculan berulang item seperti *Filter Udara*, *Kabel Gas*, dan *Cek Rem* dalam berbagai aturan memperkuat indikasi bahwa layanan-layanan tersebut sering dipilih bersamaan. Pola ini mencerminkan preferensi pelanggan yang konsisten dan berkaitan dengan kebutuhan teknis pemeliharaan kendaraan. Temuan ini berpotensi mendukung perancangan strategi

bundling dan promosi layanan yang lebih terarah.

4.5 Pembahasan

Frequent itemsets merupakan kumpulan item yang sering muncul bersamaan dalam satu transaksi dan telah melewati ambang batas minimum *support*, yang dalam penelitian ini ditetapkan sebesar 5%. Berdasarkan hasil analisis, ditemukan sebanyak 80 kombinasi item yang memenuhi kriteria tersebut. Jumlah ini menunjukkan bahwa terdapat kecenderungan pembelian yang berulang dan konsisten dari pelanggan terhadap layanan dan komponen tertentu, khususnya yang terkait dengan pemeliharaan rutin kendaraan bermotor.

Visualisasi menunjukkan Gear Set memiliki *support* tertinggi (27,55%), diikuti Ganti Ban dan Lampu Belakang, menandakan kebutuhan dominan pelanggan. Layanan lain seperti Balancing, Servis Lengkap, Kampas Rem, dan Oli Mesin juga sering muncul, mencerminkan pentingnya perawatan rutin. Seluruh association rules memiliki lift > 1, menunjukkan keterkaitan signifikan, seperti Ganti Oli → Gear Set (lift ≈ 2,5), Sporing → Ban Depan, dan Servis Ringan → Kampas Rem. Secara manajerial, pola ini dapat dimanfaatkan untuk strategi bundling layanan guna meningkatkan nilai transaksi dan kepuasan pelanggan.

SIMPULAN

Penelitian ini menunjukkan bahwa algoritma Apriori berhasil mengidentifikasi 80 pola pembelian konsumen di AHHAS PT. Mitra Pinasthika Mustika Batam dengan minimum *support* 5%, menghasilkan 38 aturan asosiasi yang


merepresentasikan keterkaitan antar layanan. Temuan ini memberikan gambaran pola perilaku pelanggan yang konsisten dan dapat dimanfaatkan untuk strategi layanan yang lebih efisien dan berbasis data.

Manajemen disarankan memanfaatkan hasil analisis ini untuk membuat paket layanan *bundling* dan sistem rekomendasi otomatis yang sesuai dengan kebiasaan pelanggan. Penelitian selanjutnya dapat dikembangkan dengan dataset yang lebih besar serta membandingkan dengan algoritma lain seperti FP-Growth untuk hasil yang lebih optimal.

DAFTAR PUSTAKA

- Anggrawan, A., Mayadi, M., & Satria, C. (2021). Menentukan Akurasi Tata Letak Barang dengan Menggunakan Algoritma Apriori dan Algoritma FP-Growth. *MATRIK: Jurnal Manajemen, Teknik Informatika Dan Rekayasa Komputer*, 21(1), 125–138. <https://doi.org/10.30812/matrik.v21i1.1260>
- Juliadi, D., Irawan, B., Bahtiar, A., & Nurdiawan, O. (2024). Penerapan Algoritma Fp-Growth Dan Association Rules Pada Pola Pembelian Pizza Hut. *JATI (Jurnal Mahasiswa Teknik Informatika)*, 7(6), 3443–3448. <https://doi.org/10.36040/jati.v7i6.8217>
- Lewis, A., Zarlis, M., & Situmorang, Z. (2021). Penerapan Data Mining Menggunakan Task Market Basket Analysis Pada Transaksi Penjualan Barang di Ab Mart dengan Algoritma Apriori. *Jurnal Media Informatika Budidarma*, 5(2), 676. <https://doi.org/10.30865/mib.v5i2.2934>

- Merliani, N. N., Khoerida, N. I., Widiawati, N. T., Triana, L. A., & Subarkah, P. (2022). Penerapan Algoritma Apriori Pada Transaksi Penjualan Untuk Rekomendasi Menu Makanan Dan Minuman. *Jurnal Nasional Teknologi Dan Sistem Informasi*, 8(1), 9–16. <https://doi.org/10.25077/teknosi.v8i1.2022.9-16>
- Ndoya, Y., & Putri, A. D. (2024). Analisis Tingkat Kepuasan Nasabah Dengan Pendekatan Fuzzy Logic Dalam Upaya Peningkatan Kualitas Pelayanan (Studi Kasus Cujk Batuaji). *Prosiding Seminar Nasional Ilmu Sosial Dan Teknologi (SNISTEK)*, 6, 314–323.
- Noviyanti, A. E., & Juanita, S. (2024). Rekomendasi Paket Pakaian Berdasarkan Pola Penjualan Menggunakan Algoritma Apriori. *Jurnal SISFOTENIKA*, 14(2), 129–139. <https://stmikpontianak.org/ojs/index.php/sisfotenika>
- Prasetya, T., Yanti, J. E., Purnamasari, A. I., Dikananda, A. R., & Nurdiawan, O. (2022). Analisis Data Transaksi Terhadap Pola Pembelian Konsumen Menggunakan Metode Algoritma Apriori. *INFORMATICS FOR EDUCATORS AND PROFESSIONAL: Journal of Informatics*, 6(1), 43. <https://doi.org/10.51211/itbi.v6i1.1688>
- Raymond, Siregar, D. L., Putri, A. D., Indrawan, M. G., & Simanjuntak, J. (2023). Pengaruh Disiplin Kerja Dan Beban Kerja Terhadap Kinerja Karyawan Pada PT. Tanjung Mutiara Perkasa. *Jurnal Sistem Informasi & Manajemen*, 129–133.
- Vidiya, E. C., & Testiana, G. (2023). Analisis Pola Pembelian di Lathansa Cafe & Ramen dengan Menggunakan Algoritma FP-Growth Berbantuan RapidMiner. *G-Tech: Jurnal Teknologi Terapan*, 7(3), 1118–1126. <https://doi.org/10.33379/gtech.v7i3.2739>
- Widodo, A. S., Rozi, A. F., Studi, P., Informasi, S., Informasi, F. T., & Buana, U. M. (2021). Analisis Pola Pembelian Di “ Kedai Bang Yhoga ” S ”. 14(1), 1–10.

	Penulis pertama, Handrik Gustapo, merupakan mahasiswa Prodi Teknik Informatika Universitas Putera Batam
	Penulis kedua, Ibu Anggia Dasa Putri, S.Kom., M.Kom, merupakan Dosen Prodi Teknik Informatika Universitas Putera Batam.