

ANALISIS KERANJANG PASAR UNTUK PENINGKATAN PENJUALAN MENGUNAKAN ALGORITMA APRIORI

Farah Dewi Ramadani, Bambang Irawan, Agus Bahtiar

Teknik Informatika, STMIK IKMI Cirebon

Jalan Perjuangan No.10B

Farahdewir24@gmail.com

ABSTRAK

Penelitian ini bertujuan untuk meningkatkan strategi penjualan melalui analisis keranjang pasar menggunakan algoritma Apriori. Saat ini, perusahaan menghadapi tantangan dalam meningkatkan penjualan produknya, dan strategi tradisional mungkin tidak lagi efektif. Oleh karena itu, penggunaan algoritma Apriori diharapkan dapat mengidentifikasi pola pembelian konsumen yang dapat digunakan untuk mengoptimalkan strategi penjualan. Penelitian ini menggunakan pendekatan analisis data berbasis algoritma Apriori. Data transaksi penjualan dari periode tertentu dikumpulkan dan dimasukkan ke dalam sistem. Algoritma Apriori kemudian diterapkan untuk mengidentifikasi pola pembelian yang umum terjadi di antara konsumen. Langkah-langkah analisis melibatkan identifikasi itemset, perhitungan nilai dukungan, dan penentuan aturan asosiasi. Hasil analisis menunjukkan adanya pola pembelian yang signifikan di antara konsumen. Beberapa itemset memiliki tingkat dukungan yang tinggi, menunjukkan popularitas tertentu di antara pelanggan. Selain itu, aturan asosiasi yang kuat ditemukan, yang dapat digunakan untuk menyusun strategi penjualan yang lebih efektif. Hasil ini memberikan wawasan tentang preferensi konsumen dan membuka peluang untuk meningkatkan penjualan dengan menyesuaikan strategi penjualan perusahaan. Penerapan algoritma Apriori membuka peluang baru untuk meningkatkan penjualan melalui pemahaman yang lebih baik tentang pola pembelian konsumen. Hasil dan Diskusi menyoroti pola pembelian yang berhasil diidentifikasi dan menggambarkan implikasinya dalam konteks bisnis, seperti peningkatan penjualan, efisiensi persediaan, dan pengembangan strategi pemasaran yang lebih cermat. Untuk menguji hasil penelitian ini digunakan nilai minimum Support 30% dan nilai Confidence 80% serta tahap evaluasi menggunakan lift ratio minimum 100% dari hasil pengujian tersebut terdapat beberapa yang memenuhi syarat aturan asosiasi. Misalnya kombinasi, minyak dan beras yang memiliki nilai Support 40%, nilai Confidence 30% dan nilai lift ratio 1,44. Implikasi dari hasil penemuan pola pembelian ini bisa dijadikan strategi penjualan Contohnya, saran untuk penempatan produk, promo khusus untuk produk dan manajemen stok yang efisien

Kata kunci : Analisis Keranjang Pasar, Algoritma Apriori, Pola Pembelian, Penjualan, Strategi Pemasaran.

1. PENDAHULUAN

Dalam era globalisasi dan persaingan bisnis yang semakin ketat, strategi penjualan menjadi kunci utama bagi kesuksesan perusahaan. Perkembangan teknologi informasi, khususnya dalam bidang algoritma, memberikan peluang baru untuk meningkatkan efektivitas strategi penjualan. Penelitian ini akan membahas Analisis Keranjang Pasar untuk Peningkatan Penjualan dengan menggunakan algoritma Apriori. Algoritma ini menjadi terdepan dalam menganalisis pola pembelian konsumen, membuka potensi untuk mengoptimalkan strategi penjualan. Seiring dengan dinamika pasar yang terus berubah, pemahaman mendalam terhadap preferensi konsumen melalui analisis keranjang pasar dapat menjadi kunci keberhasilan dalam mencapai pertumbuhan penjualan yang berkelanjutan. Oleh karena itu, penelitian ini memiliki tujuan untuk menjelajahi potensi dan manfaat penerapan algoritma Apriori dalam meningkatkan performa penjualan perusahaan di tengah tantangan pasar yang dinamis. Meskipun algoritma Apriori menjanjikan potensi besar dalam meningkatkan strategi penjualan melalui analisis keranjang pasar, sejumlah permasalahan dan

tantangan muncul yang perlu diperhatikan dalam konteks Informatika.

Kompleksitas data transaksi penjualan dapat menjadi hambatan utama. Dengan pertumbuhan volume data yang pesat, perusahaan dihadapkan pada tugas pemrosesan dan analisis data yang membutuhkan kekuatan komputasi tinggi. Variasi yang signifikan dalam pola pembelian konsumen menambah tingkat kesulitan dalam mengidentifikasi aturan asosiasi yang konsisten dan relevan. Dalam konteks di mana preferensi pelanggan dapat bervariasi secara dramatis, perumusan strategi penjualan yang responsif dan terfokus dapat menjadi tantangan yang rumit. Selain itu, keamanan data menjadi perhatian utama. Analisis keranjang pasar melibatkan manipulasi data penjualan yang dapat mencakup informasi pribadi pelanggan. Dalam mengimplementasikan algoritma Apriori, perusahaan harus menjaga keamanan dan privasi data dengan memastikan bahwa akses terhadap informasi sensitif dibatasi dan tindakan keamanan data yang cermat diimplementasikan. Kesulitan interpretasi hasil analisis juga menjadi fokus, karena pemahaman yang tidak akurat dari pola pembelian dapat mengarah pada pengambilan keputusan yang tidak tepat. Selanjutnya,

pelibatan staf yang memiliki pemahaman yang cukup tentang algoritma Apriori menjadi penting. Penerapan yang tidak tepat atau interpretasi yang keliru dapat mengurangi efektivitas analisis keranjang pasar. Oleh karena itu, perusahaan harus berinvestasi dalam pelatihan dan pengembangan keterampilan analitis untuk memastikan tim memiliki pemahaman yang cukup untuk mengelola algoritma ini secara efisien. Keseluruhan, memahami dan mengatasi tantangan-tantangan ini dalam konteks Informatika menjadi krusial untuk memaksimalkan potensi algoritma Apriori dalam meningkatkan penjualan dan daya saing perusahaan.

Tiga penelitian terdahulu yang dibahas menyoroati aspek-aspek berbeda dalam bidang bisnis dan pelayanan. Pertama, penelitian tentang pola pembelian konsumen suku cadang motor melalui algoritma Apriori memberikan wawasan berharga mengenai hubungan produk yang sering dibeli bersama, seperti kampas rem dan oli mesin sepeda motor. Meskipun memberikan informasi penting, penelitian ini mengakui keterbatasan dalam dataset dan mengusulkan perlunya dataset yang lebih luas dan beragam untuk analisis yang lebih mendalam[1].

Kedua, penelitian terkait kekosongan stok barang dalam apotek menggunakan teknik association rule mining dan algoritma Apriori memberikan solusi untuk meningkatkan efisiensi layanan kefarmasian dengan memahami pola belanja pelanggan. Hasil uji coba menunjukkan bahwa parameter support dan confidence memengaruhi hasil analisis, dan penelitian ini memberikan kontribusi berharga dalam merancang strategi manajemen stok dan pemasaran yang lebih efektif[2].

Ketiga, penelitian tentang kecepatan pelayanan kefarmasian di Apotek Mooladhara di Denpasar, Bali, mengeksplorasi penggunaan data mining dengan algoritma Apriori untuk menemukan pola belanja pelanggan dan mengatasi kesulitan menemukan obat. Hasilnya menunjukkan identifikasi barang yang sering dibeli bersamaan dan memberikan kontribusi dalam meningkatkan efisiensi layanan kefarmasian. Keseluruhan, ketiga penelitian ini membahas peran krusial data mining dan algoritma Apriori dalam memahami perilaku konsumen, mengoptimalkan tata letak barang, dan meningkatkan efisiensi pelayanan dalam konteks suku cadang motor dan industri farmasi.[3]

Penelitian ini bertujuan untuk mencapai beberapa tujuan utama yang secara komprehensif mendukung pencapaian peningkatan penjualan melalui analisis keranjang pasar menggunakan algoritma Apriori. Penelitian ini bertujuan untuk mengidentifikasi pola pembelian yang signifikan di antara konsumen, dengan fokus pada itemset dan aturan asosiasi yang dapat memberikan wawasan mendalam tentang preferensi pembelian mereka. Penelitian ini bertujuan untuk mengoptimalkan strategi penjualan perusahaan dengan memanfaatkan hasil analisis tersebut, seperti menyusun paket produk yang lebih menarik dan

menentukan strategi harga yang lebih dinamis. Selain itu, tujuan penelitian ini adalah memberikan kontribusi pada literatur ilmiah dengan memperluas pemahaman tentang aplikasi algoritma Apriori dalam konteks strategi penjualan, khususnya dalam analisis keranjang pasar. Dengan demikian, penelitian ini diharapkan dapat menyumbangkan pengetahuan baru dan wawasan yang dapat digunakan sebagai referensi bagi peneliti dan praktisi di bidang ini. Secara praktis, penelitian ini bertujuan untuk memberikan kontribusi nyata bagi perusahaan dengan menyediakan landasan yang kuat untuk perbaikan strategi penjualan mereka. Dengan memahami pola pembelian konsumen, perusahaan dapat merespon secara lebih cepat dan akurat terhadap perubahan tren pasar. Oleh karena itu, penelitian ini memiliki signifikansi penting dalam membantu perusahaan meningkatkan efisiensi operasional dan mencapai pertumbuhan penjualan yang berkelanjutan di tengah persaingan yang semakin ketat.

Dalam merespon tantangan meningkatnya kompleksitas data penjualan dan keranjang pasar, penelitian ini akan menerapkan pendekatan analisis data berbasis algoritma Apriori. Metode ini dipilih karena kemampuannya yang terbukti dalam mengungkap pola pembelian yang signifikan. Data transaksi penjualan dari periode tertentu akan dikumpulkan dan dimasukkan ke dalam sistem, di mana algoritma Apriori akan diterapkan untuk mengidentifikasi itemset dan aturan asosiasi yang dapat digunakan sebagai dasar strategi penjualan. Pendekatan ini melibatkan langkah-langkah analisis, termasuk identifikasi itemset, perhitungan nilai dukungan, dan penentuan aturan asosiasi yang relevan. Teknik analisis data ini akan memungkinkan kami memahami lebih baik preferensi konsumen, membuka peluang untuk peningkatan penjualan melalui penyusunan strategi yang lebih terfokus dan responsif. Dengan demikian, pendekatan ini diharapkan dapat memberikan wawasan mendalam dan solusi praktis untuk meningkatkan kinerja penjualan perusahaan.

Melalui analisis keranjang pasar menggunakan algoritma Apriori, penelitian ini diharapkan memberikan implikasi yang substansial bagi strategi penjualan perusahaan. Hasil analisis yang mendalam terhadap pola pembelian konsumen akan memberikan pemahaman yang lebih mendalam tentang preferensi pasar, membuka peluang untuk penyesuaian strategi pemasaran dan promosi produk yang lebih terarah. Implikasi potensial mencakup kemampuan perusahaan untuk mengantisipasi tren pasar, meningkatkan efektivitas strategi penjualan, dan mengoptimalkan stok dengan memahami hubungan antarproduk yang sering dibeli bersama. Selain itu, pemahaman yang diperoleh dari hasil penelitian dapat mengarah pada pengembangan strategi harga yang lebih akurat dan dinamis, menciptakan keunggulan kompetitif dalam menghadapi persaingan yang ketat. Implikasi lainnya terletak pada peningkatan efisiensi operasional perusahaan, dengan potensi mengurangi pemborosan

dan meningkatkan efisiensi rantai pasokan. Lebih jauh lagi, hasil penelitian ini memiliki potensi untuk mendukung pengembangan produk baru atau pengembangan lini produk yang lebih sesuai dengan kebutuhan pelanggan. Dalam konteks akademis, penelitian ini diharapkan memberikan kontribusi pada pengembangan ilmu pengetahuan di bidang analisis keranjang pasar dan aplikasi algoritma Apriori. Implikasi teoritis dari penelitian ini dapat membuka pintu bagi penelitian lanjutan dalam menggali lebih dalam pola pembelian konsumen dan pengembangan metode analisis yang lebih canggih. Dengan demikian, penelitian ini diharapkan memberikan dampak positif dan relevan di berbagai tingkatan, dari tingkat perusahaan hingga kontribusi pada pemahaman ilmiah di bidang terkait.

2. TINJAUAN PUSTAKA

Hasil review dari penelitian-penelitian terdahulu yang berjudul "Penerapan Data Mining Menggunakan Algoritma Apriori Terhadap Data Transaksi Sebagai Pendukung Informasi Strategi Penjualan" yang di tulis oleh Takdirillah, Robby yaitu membahas tentang Permasalahan yang terjadi di industri ritel di Provinsi Jawa Barat adalah adanya peningkatan persaingan yang diikuti dengan pertumbuhan penerapan teknologi informasi. Salah satu tantangan utama adalah manajemen stok yang berlebihan, yang dapat merugikan pemilik usaha karena kurangnya pemahaman tentang preferensi pembeli dan kurangnya strategi penjualan yang efektif. Untuk mengatasi hal ini, penting untuk menerapkan teknologi informasi seperti teknik data mining dengan algoritma Apriori untuk mengolah data transaksi penjualan. Hal ini akan membantu pemilik usaha dalam memahami keterkaitan antar produk dan mengembangkan strategi penjualan yang lebih efisien, sehingga dapat mengurangi risiko penumpukan stok yang tidak terjual.

2.1. Data Mining

Data mining adalah proses pengumpulan dan pengolahan data yang bertujuan untuk mengekstrak informasi penting dari data. Data mining memiliki tiga tujuan, yaitu sebagai sarana untuk menjelaskan (*explanatory*), untuk konfirmasi (*confirmatory*), dan untuk eksplorasi (*exploratory*). Ia juga melibatkan beberapa metode seperti *Association*, *Classification*, *Regression*, dan *Clustering*. [4]

2.2. Aturan Asosisa

Aturan Asosiasi, yang juga dikenal sebagai Association rules, merupakan salah satu teknik dalam data mining yang memiliki kegunaan khusus dalam mengidentifikasi aturan asosiatif terkait dengan suatu set barang. Proses pembentukan aturan asosiasi ini melibatkan analisis pola data yang sering muncul, yang dikenal sebagai Frequent patterns, dengan memanfaatkan parameter Support dan Confidence. Support mencerminkan seberapa sering suatu item

muncul dalam suatu basis data, sementara Confidence menunjukkan seberapa sering pernyataan atau asosiasi tersebut benar. Dengan menggunakan pendekatan ini, aturan asosiasi dapat dihasilkan untuk mengidentifikasi hubungan yang signifikan dan penting antar barang atau elemen dalam suatu konteks data tertentu. *Support* dapat dinyatakan sebagai berikut:

$$Support = \frac{Total\ Transaksi\ X\ dan\ Y}{Total\ Transaksi}$$

Untuk mencari nilai *Confidence* dapat menggunakan rumus sebagai berikut

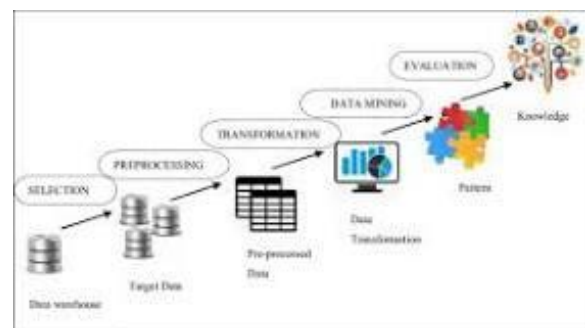
$$Confidence = \frac{Total\ Transaksi\ X\ dan\ Y}{Total\ Transaksi\ X} \times 100 \quad [5]$$

2.3. Algoritma Apriori

Algoritma Apriori adalah jenis aturan asosiasi pada data mining. Algoritma ini bertujuan untuk mencari kombinasi itemset yang memiliki suatu nilai frekuensi tertentu sesuai dengan kriteria atau filter yang diinginkan. Algoritma ini diajukan oleh R. Agrawal dan R. Srikant pada tahun 1994 (Kusrini, & Emha Taufiq Luthfi). Hasil dari algoritma ini dapat digunakan untuk membantu dalam pengambilan keputusan oleh pihak manajemen. Algoritma Apriori melakukan pendekatan iteratif yang dikenal dengan pencarian level-wise, di mana k-itemset digunakan untuk mengeksplorasi atau menemukan (k+1)-itemset. Oleh karena itu, algoritma Apriori dibagi menjadi beberapa tahap yang disebut iterasi. Setiap iterasi menghasilkan pola frekuensi tinggi dengan panjang yang sama, dimulai dari iterasi pertama yang menghasilkan pola frekuensi tinggi dengan panjang satu. [6]

3. METODE PENELITIAN

Metode pengembangan data mining yang diterapkan untuk menganalisis data melibatkan langkah-langkah pada proses tahapan knowledge discovery in databases (KDD). Proses ini terdiri dari beberapa tahapan, yakni Data, Seleksi data, Preprocessing, Transformasi, Data Mining, dan Evaluasi.



Gambar 1. Metode KDD

Sumber data yang digunakan dalam penelitian ini diperoleh dari Kaggle, sebuah platform terkemuka dalam komunitas data science yang menyediakan akses kepada peneliti, ilmuwan data, dan praktisi di

berbagai bidang. Data yang digunakan yakni data transaksi penjualan, Dari data yang sudah ada dilanjutkan dengan proses preparasi data melalui tahapan data selection, data cleaning, dan data transformation[5]

a. Data Selection

Sebelum tahap penambahan informasi KDD dimulai, harus dilakukan pemilihan data (data Selection) dan pemilihan data dari sekumpulan data operasional (seleksi). Data seleksi yang digunakan dalam proses data mining disimpan dalam file yang terpisah dari database operasional.

b. Pre-processing /clening

Sebelum melakukan proses data mining, harus dilakukan proses pembersihan terhadap data yang diinginkan KDD. Proses pembersihan mencakup, namun tidak terbatas pada, penghapusan data duplikat, pemeriksaan data yang tidak konsisten, dan koreksi kesalahan pada data.

c. Data Transformation

Ini adalah proses mengubah data yang dipilih sehingga cocok untuk proses penambahan data. Proses pengkodean KDD merupakan proses kreatif dan sangat bergantung pada jenis dan pola informasi yang dicari dalam database.

d. Data mining

Ini adalah proses menemukan pola dan informasi menarik dalam data terpilih dengan menggunakan teknik dan metode tertentu. Teknik, metode, dan algoritma penambahan data sangat bervariasi. Pemilihan metode atau algoritma yang tepat sangat bergantung pada tujuan Anda dan proses KDD secara keseluruhan.

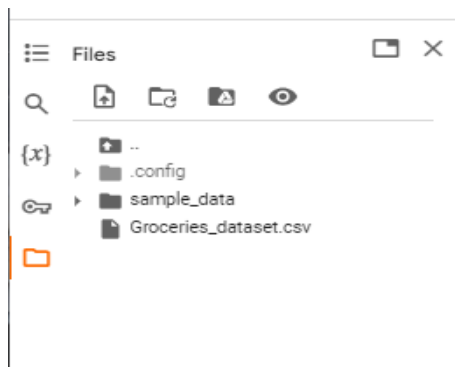
e. Evaluasi

Pola informasi yang dihasilkan dari proses data mining harus disajikan dalam format yang mudah dipahami oleh pemangku kepentingan. Fase ini merupakan bagian dari proses KDD yang disebut interpretasi.

4. HASIL DAN PEMBAHASAN


4.1. Data

Penelitian menggunakan data seyang didapatkan dalam bentuk format excel csv yang Bernama bread_basket.csv yang di peroleh dari sumber dataset *Kaggle*, data terdapat kurang lebih 60 data transaksi.



Gambar 2. Import data penyimpanan

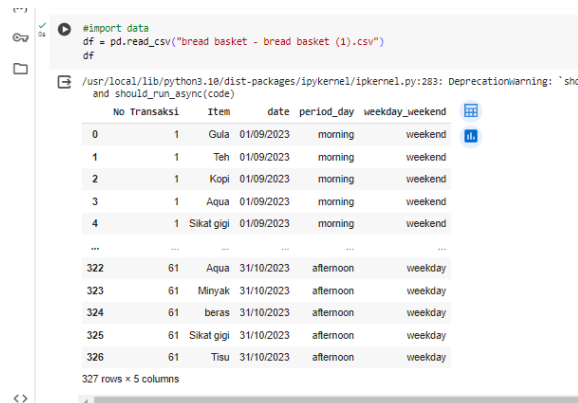
Berdasarkan gambar 2 tahap ini dilakukan persiapan data yang akan diolah. Kemudian data tersebut di import ke dalam penyimpanan yang ada pada *Google Colab*.



Gambar 3. Import Library

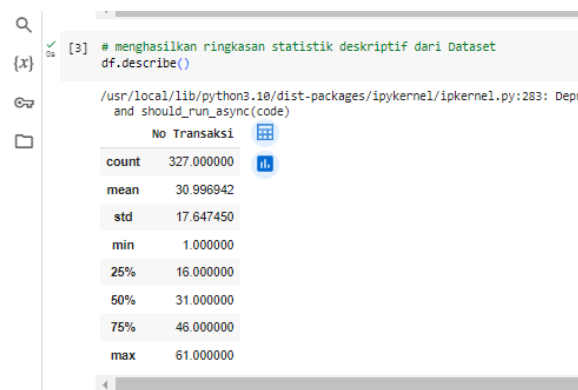
Berdasarkan gambar 3 Selanjutnya adalah proses import *library* yang diperlukan untuk pengolahan data transaksi di google colab adalah sebagai berikut:

- a. numpy untuk komputasi numerik
- b. pandas digunakan untuk membaca data excel
- c. mlxtend.frequent_patterns untuk mengimport fungsi apriori dan juga associaton rulesnya untuk mengeneret pola aturan asosiasinya



Gambar 4. Mengeksplor Data

Berdasarkan gambar 4 Selanjutnya adalah proses meload dan eksplor data fungsi ini digunakan untuk memuat data untuk proses mining terhadap data sebelum dilakukannya proses data mining



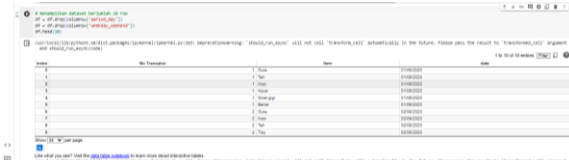
Gambar 5. Membaca File Pada Excel

Pada gambar 4 tahap selanjutnya yaitu *describe* proses digunakan untuk menampilkan deskripsi

statistik yang datanya bertipe numerik atau angka yang nantinya proses tersebut akan ditampilkan statistiknya

4.1.1. Data Selection

Pada tahap data selection ini merupakan tahapan awal untuk menentukan data yang akan diproses oleh data mining dengan menggunakan algoritma apriori.

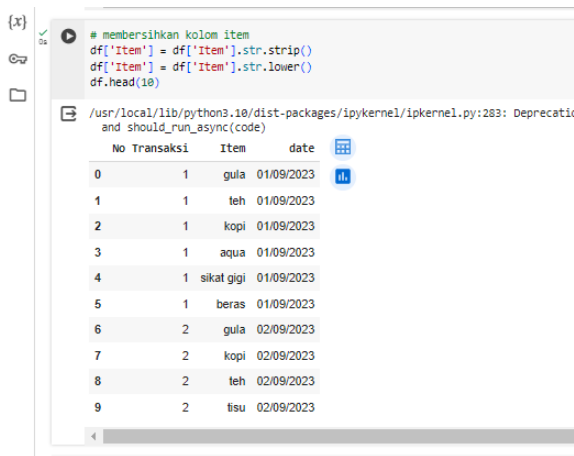


Gambar 6. Seleksi Data

Pada gambar 6 menampilkan tahap dilakukannya proses pemilihan data seperti pemilihan atribut yang di butuhkan untuk melakukan penelitian ini.

4.1.2. Preprocessing

Pada tahap ini selanjutnya dilakukan Proses pembersihan data atau preprocessing, melibatkan analisis awal atribut data untuk mengidentifikasi nilai yang hilang atau tidak konsisten. Tujuannya adalah mempersiapkan data dengan mengisi nilai yang hilang atau menghapusnya agar sesuai untuk analisis lebih lanjut.



Gambar 7. preprocessing data

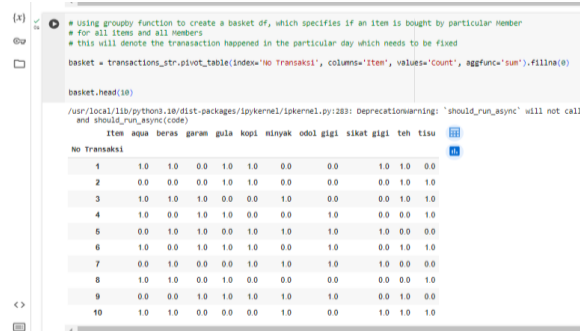
Berdasarkan gambar 7 menampilkan hasil pembersihan data yang sudah lebih siap dan valid untuk di gunakan dalam penelitian atau analisis data.

4.1.3. Transformation

Data yang sudah dibersihkan dan diperbaiki pada penelitian ini akan di transformasikan ke dalam file terpisah dengan format csv sehingga data tersebut layak dan siap untuk di lakukan proses data mining. Proses transformasi ini dapat melibatkan berbagai teknik seperti pengubahan skala, pengkodean, normalisasi, atau perubahan struktur data agar lebih cocok untuk analisis atau pemodelan. Sebagai contoh,

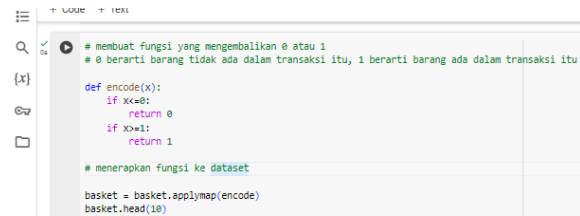
digunakan label encoding yang menggantikan nilai-nilai kategori dengan nilai-nilai numerik.

Dalam konteks ini, ketika label encoding menunjukkan angka 0, itu menandakan bahwa tidak ada transaksi, sementara label encoding dengan nilai 1 menunjukkan adanya transaksi. Dengan menerapkan label encoding, data dapat diubah ke dalam format yang lebih sesuai untuk penggunaan algoritma Apriori dalam analisis asosiasi pembelian pelanggan.



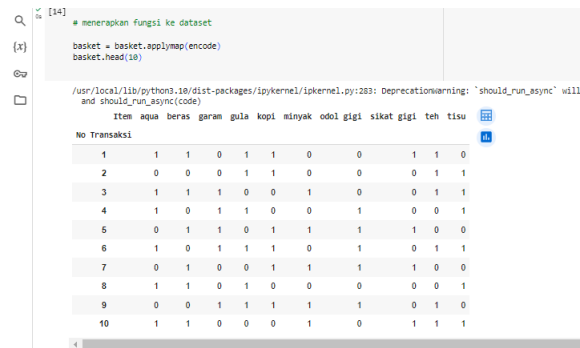
Gambar 8. Memilih Variabel

Berdasarkan gambar 8 menampilkan hasil pemilihan variabel yang akan di gunakan pada saat proses data mining. Kemudian melakukan encoding dimana jika barang kurang dari sama dengan 0 maka keranjang tersebut bernilai 0 yang berarti barang itu tidak ada dalam transaksi dan jika lebih dari 1 maka nilainya adalah 1 yang berarti barang itu ada dalam transaksi.



Gambar 9. Pengkodean Hot Encoding

Berdasarkan gambar 9 menampilkan script untuk melakukan proses pengkodean Hot Encoding.



Gambar 10. Mengkodekan Dataset

Berdasarkan gambar 10 menampilkan hasil dari proses hot_encoding yaitu menerapkan fungsi boolean

yang mewakili nilai *true* dan *false* dimana 1 bernilai *true* dan 0 bernilai *false*.

4.1.4. Data Mining

Pada proses mining ini diterapkan teknik data mining yaitu analisis asosiasi dengan menggunakan algoritma apriori. Teknik ini melakukan pencarian pola frekuensi tertinggi dan mencari aturan asosiatif. Tahap awal dari teknik analisis asosiasi ini adalah pembentukan pola frekuensi dengan mencari kombinasi item yang memenuhi syarat minimum dari nilai support. Selanjutnya menggunakan algoritma apriori untuk menemukan jumlah itemset frekuensi secara efisien. Tahapan algoritma yaitu pembangkitan kandidat dan pemangkasan kandidat. Setelah itemset yang frekuensi telah ditemukan, tahap akhir yaitu pembentukan aturan asosiasi. Hasil yang diperoleh dari penerapan algoritma Apriori adalah aturan (rule) yang menggambarkan kekuatan hubungan dari setiap atribut.

Proses analisis asosiasi terdiri dari dua tahap utama, yaitu a) analisis pola frekuensi tertinggi dengan mencari kombinasi item yang memenuhi syarat minimum skor support, dan b) pembentukan aturan asosiasi yang memenuhi syarat minimum untuk *confidence*. Rumus untuk menemukan nilai minimum *support* dan *confidence* sebagai berikut:

Support (1) Nilai support sebuah item diperoleh berdasarkan persamaan (1).

$$Support (1) = \frac{Jumlah\ transaksi\ mengandung\ item\ 1}{Total\ transaksi}$$

Sedangkan nilai dari support kedua diperoleh berdasarkan persamaan (2).

$$Support (2) = \frac{Jumlah\ transaksi\ mengandung\ Item\ 1\ dan\ Item\ 2}{Total\ transaksi}$$

Sedangkan nilai dari support ketiga diperoleh berdasarkan persamaan (3).

$$Support (3) = \frac{Jumlah\ transaksi\ mengandung\ Item\ 1,\ 2\ dan\ Item\ 3}{Total\ transaksi}$$

Nilai *confidence* dapat dihitung menggunakan persamaan (4).

$$Confidence = (B|A) = \frac{Jumlah\ transaksi\ mengandung\ Item\ 1\ dan\ Item\ 2}{Jumlah\ transaksi\ mengandung\ Item\ 1} \times 100$$

1.) Analisis Frekuensi Tertinggi

Tahapan awal dalam pengelolaan data transaksi menggunakan Algoritma Apriori melibatkan penentuan parameter khusus, yaitu nilai minimum *support*, dengan rentang antara 0 hingga 1. Dalam penelitian ini, nilai minimum *support* ditetapkan sebesar 0,03 atau 3% untuk memfokuskan analisis pada pola yang memiliki dampak signifikan. Nilai *support* yang memenuhi batas minimum digunakan untuk menggabungkan dengan itemset lain, dan

perhitungan nilai *support* diulang hingga tidak ada lagi kombinasi itemset yang terbentuk. Itemset yang tidak memenuhi nilai minimum *support* dieliminasi dan tidak digunakan pada tahapan berikutnya untuk mengevaluasi nilai *confidence* dan nilai *lift ratio*.

```
# menggunakan 'algoritma apriori' dengan min_support=0,03 (3% dari 9465)
# artinya item tersebut harus ada dalam minimal 282 transaksi dari 9465 transaksi :
frequent_itemsets = apriori(basket, min_support = 0.03, use_colnames = True)

# Menampilkan frequent itemsets
print("Frequent 1-itemset:")
print(frequent_itemsets[frequent_itemsets['itemsets'].apply(len) == 1])
```

support	itemsets
0	0.557377 (aqua)
1	0.557377 (beras)
2	0.491803 (garam)
3	0.606557 (gula)
4	0.540984 (kopi)
5	0.508197 (minyak)
6	0.540984 (odol gigi)
7	0.508197 (sikat gigi)
8	0.491803 (teh)
9	0.557377 (tisu)

Gambar 11. frequent 1-Itemset

Pada gambar 11 menampilkan proses dan hasil dalam mencari nilai *support* untuk kombinasi 1-Itemset yang telah dihitung menggunakan perintah python. Setelah hasil perintah *python* kita buatkan hasil mencari frequent 1-Itemset menjadi tabel sesuai dengan hasil yang di dapatkan pada gambar 11.

Tabel 1. frequent 1-Itemset

Transaction	Itemsets	Support
0	(aqua)	0.557377
1	(beras)	0.557377
2	(garam)	0.491803
3	(gula)	0.606557
4	(kopi)	0.540984
5	(minyak)	0.508197
6	(odol gigi)	0.540984
7	(sikat gigi)	0.508197
8	(teh)	0.491803
9	(tisu)	0.557377

Tabel 1 menunjukkan pola kombinasi 1-Itemset yang memenuhi nilai *support* minimum. Sebagai contoh, "gula" memiliki nilai *support* sebesar 0.606557, menjadi pola frekuensi tinggi dalam pembentukan kombinasi 1-Itemset. Proses perhitungan serupa dilakukan untuk item-set lain, seperti yang diilustrasikan dalam persamaan 2 untuk mendapatkan informasi *support 2-Itemset*.

Proses perhitungan untuk item-set lainnya juga mengikuti metode yang serupa, dan hasilnya dicatat dalam tabel, seperti yang terlihat dalam gambar 12 menggunakan perintah *Python*.

Pada gambar 12 menampilkan proses dan hasil dalam mencari nilai *support* untuk kombinasi 2-Itemset yang telah dihitung menggunakan perintah *python*.

Setelah hasil perintah *python* kita buatkan hasil mencari *frequent 2-Itemset* menjadi tabel sesuai dengan hasil yang di dapatkan pada gambar 12.


```
[38] # menggunakan 'algoritma apriori' dengan min_support=0,03 (3% dari 9465)
# artinya item tersebut harus ada dalam minimal 282 transaksi dari 9465 tr
# frequent itemset
frequent_itemsets = apriori(basket, min_support = 0.3, use_colnames = True)

# Menampilkan frequent itemsets
print("Frequent 2-itemset:")
print(frequent_itemsets[frequent_itemsets['itemsets'].apply(len) == 2])

/usr/local/lib/python3.10/dist-packages/ipykernel/ipkernel.py:283: Deprecat
and should_run_async(code)
/usr/local/lib/python3.10/dist-packages/mlxtend/frequent_patterns/fpcommon
warnings.warn(
Frequent 2-itemset:
      support      itemsets
10  0.311475    (aqua, beras)
11  0.360656    (aqua, gula)
12  0.360656    (tisu, aqua)
13  0.311475    (gula, beras)
14  0.409836    (minyak, beras)
15  0.360656    (sikat gigi, beras)
16  0.311475    (tisu, beras)
17  0.393443    (odol gigi, garam)
18  0.344262    (garam, teh)
19  0.393443    (kopi, gula)
20  0.311475    (tisu, gula)
21  0.393443    (kopi, odol gigi)
22  0.311475    (minyak, sikat gigi)
23  0.311475    (minyak, tisu)
```

Gambar 12. Frequent 2-Itemset

Tabel 2. Support 2-Itemset

Transaction	Itemsets	Support
10	(aqua, beras)	0.311475
11	(aqua, gula)	0.360656
12	(tisu, gula)	0.360656
13	(gula, beras)	0.311475
14	(minyak, beras)	0.409836
15	(sikat gigi, beras)	0.360656
16	(tisu, beras)	0.311475
17	(odol gigi, garam)	0.393443
18	(garam, teh)	0.344262
19	(kopi, gula)	0.393443
20	(tisu, gula)	0.311475
21	(kopi, odol gigi)	0.393443
22	(minyak, sikat gigi)	0.311475
23	(minyak, tisu)	0.311475

Tabel 2 menyajikan empatbelas pola kombinasi 2-Itemset yang memenuhi nilai support minimum. Contoh salah satunya adalah kombinasi (minyak,beras) dengan nilai *support* sebesar 0.409836, yang menjadi pola frekuensi tinggi dalam pembentukan Kombinasi 2-Itemset. Proses perhitungan untuk kombinasi menu lainnya dilakukan dengan pendekatan yang serupa, dan hasilnya mencakup informasi *support* untuk 3-Itemset, dihitung menggunakan persamaan 3 dan diimplementasikan dengan perintah *Python*.

```
# menggunakan 'algoritma apriori' dengan min_support=0,03 (3% dari 9465)
# artinya item tersebut harus ada dalam minimal 282 transaksi jika tidak memenuhi n
# frequent itemset
frequent_itemsets = apriori(basket, min_support = 0.3, use_colnames = True)

# Menampilkan frequent itemsets
print("Frequent 3-itemset:")
print(frequent_itemsets[frequent_itemsets['itemsets'].apply(len) == 3])

/usr/local/lib/python3.10/dist-packages/ipykernel/ipkernel.py:283: DeprecationWarning: 'should_run_async' will not call 'transfo
and should_run_async(code)
/usr/local/lib/python3.10/dist-packages/mlxtend/frequent_patterns/fpcommon.py:118: DeprecationWarning: '
warnings.warn(
Frequent 3-itemset:
      support      itemsets
24  0.311475    (minyak, sikat gigi, beras)
```

Gambar 13. Frequent 3-Itemset

Gambar 13 menampilkan proses dan hasil dalam mencari nilai *support* untuk kombinasi 3-Itemset yang telah dihitung menggunakan perintah *python*. Setelah

hasil perintah *python* kita buat hasil mencari *frequent 2-Itemset* menjadi tabel sesuai dengan hasil yang di dapatkan pada gambar 13.

Tabel 3. Support 3-Itemset

Transaction	Itemsets	Support
24	(minyak, sikat gigi, beras)	0.311475

Tabel 3 menunjukkan ada satu pola kombinasi 3-Itemset yang memenuhi nilai minimum *support*. Seperti contoh (minyak, sikat gigi, beras) dengan nilai *support* sebesar 0.311475 yang menjadi pola frekuensi tinggi dalam pembentukan kombinasi 3-Itemset.

2.) Pembentukan Aturan Asosiasi

Setelah mengidentifikasi semua pola frekuensi tinggi, langkah berikutnya adalah mencari aturan asosiasi yang memenuhi persyaratan nilai *confidence* minimum, yang telah ditetapkan pada 0,8atau 80% dari kombinasi 2-Itemset dan 3-Itemset yang telah diidentifikasi sebelumnya. Pemilihan nilai *confidence* minimum dilakukan untuk memastikan bahwa aturan asosiasi yang terbentuk memiliki tingkat kepercayaan yang memadai. Jika nilai *confidence* yang dihasilkan tidak mencapai nilai minimum yang ditetapkan, aturan tersebut akan dihapus atau dieliminasi. Dalam beberapa situasi, terjadi perubahan posisi item pada beberapa kombinasi, yang disebabkan oleh fakta bahwa aturan asosiasi di mana salah satu item lebih umum dalam dataset umumnya akan memiliki nilai *support* yang lebih tinggi.

```
# sekarang buat aturan dari frequent itemset yang dihasilkan di atas
rules = association_rules(frequent_itemsets, metric="confidence", min_threshold=0.8)
rules = rules[['antecedents', 'consequents', 'support', 'confidence']]
rules

/usr/local/lib/python3.10/dist-packages/ipykernel/ipkernel.py:283: DeprecationWarning: 'should_run_async' will not call 'transfo
and should_run_async(code)
antecedents consequents support confidence
0 (minyak) (beras) 0.409836 0.806452
1 (garam) (odol gigi) 0.393443 0.800000
2 (beras, sikat gigi) (minyak) 0.311475 0.863636
3 (sikat gigi, minyak) (beras) 0.311475 1.000000
```

Gambar 14. Mencari nilai min confidence

Berdasarkan gambar 14 menampilkan *script* dan hasil untuk menentukan nilai *confidence* minimum yang akan di gunakan dalam penelitian ini . Selanjutnya dari hasil perintah *python* kita buat hasil mencari minimum *confidence* pada *frequent 2-Itemset* yang sudah dicari nilai *support*nya menjadi tabel sesuai dengan hasil yang didapatkan pada Tabel 4.

Tabel 4. Confidence

No	Item 1	Item 2	Confidence	Persentase
0	(minyak)	(beras)	0.806452	80%
1	(garam)	(odol gigi)	0.800000	80%
2	(minyak, sikat gigi)	(beras)	1.000000	20%
3	(beras, sikat gigi)	(minyak)	0.863636	90%

Tabel 4 menunjukkan empat peraturan asosiasi yang memenuhi tingkat kepercayaan minimum, salah satunya adalah hubungan antara (beras, sikat gigi , minyak) dengan tingkat kepercayaan sebesar 0.863636, menjadikannya peraturan asosiasi dengan tingkat kepercayaan tertinggi. Tahap berikutnya melibatkan penentuan nilai *lift ratio*, di mana pengujian menggunakan *lift ratio* bertujuan untuk memperkuat keabsahan peraturan asosiasi tersebut. Jika nilai *lift ratio* sama dengan atau lebih besar dari 1, ini menunjukkan kekuatan peraturan asosiasi. Sebaliknya, jika nilai *lift ratio* kurang dari 1, hal ini menandakan adanya ketergantungan antara dua itemset atau item. Dalam konteks analisis asosiasi, hal ini menggambarkan bahwa kedua item cenderung muncul bersamaan dengan frekuensi yang lebih rendah. Penting untuk diingat bahwa interpretasi nilai *lift ratio* perlu dipertimbangkan bersama-sama dengan nilai *support* dan *confidence*, karena tidak dapat dipahami secara terpisah.

4.1.5. Evaluasi

Hasil data mining di atas aturan asosiasi yang memiliki keterkaitan terkuat antar satu sama lain adalah item (minyak , beras) dengan nilai *lift* 1.446869 ,(garam, odol gigi) dengan nilai *lift* 1.478788 , (minyak ,sikat gigi, beras) dengan nilai *lift* 1.794118 dan (beras,sikat gigi,minyak) dengan *lift* 1.699413 . Maka aturan asosiasi yang akan ditampilkan adalah aturan asosiasi yang memiliki nilai *lift* 1 atau lebih.

Hasil pembentukan aturan asosiasi dengan bahasa pemrograman *Python* di atas, dapat dilihat bahwa besarnya nilai *support*, *confidence* dan *lift* dari aturan asosiasi yang telah terbentuk. Aturan asosiasi tersebut bisa dilihat pada tabel 4.5 . Hasil pembentukan aturan asosiasi, semuanya memenuhi persyaratan nilai *lift* untuk ditampilkan kepada pengguna karena memiliki nilai sama dengan 1 atau lebih. Hasil dari proses data mining pada tabel 4.5 dapat digunakan sebagai penunjang informasi dalam menentukan keputusan strategi penjualan pada toko ritel. Informasi keterkaitan yang kuat antara rokok dengan tersebut dapat berguna dalam menentukan barang yang akan dipaketkan secara bersamaan sehingga mempunyai peluang dibeli lebih besar ataupun digunakan dalam menentukan barang yang akan direkomendasikan kepada pembeli.

```
# Mengevaluasi hasil aturan asosiasi yang sudah memenuhi nilai support dan confidence menggunakan metrik lift ratio
rules = association_rules(frequent_itemsets, metric='lift', min_threshold=1)
rules = association_rules(frequent_itemsets, metric='confidence', min_threshold=0.8)
rules = rules[['antecedents', 'consequents', 'support', 'confidence', 'lift']]
rules
```

	antecedents	consequents	support	confidence	lift
0	(minyak)	(beras)	0.409836	0.806452	1.446869
1	(garam)	(odol gigi)	0.393443	0.800000	1.478788
2	(minyak, sikat gigi)	(beras)	0.311475	1.000000	1.794118
3	(beras, sikat gigi)	(minyak)	0.311475	0.863636	1.699413

Gambar 15. Mencari min lift ratio

Berdasarkan gambar 15 menampilkan hasil nilai kombinasi itemset yang memenuhi syarat min lift ratio menggunakan perintah *python*

Tabel 4. lift ratio

No	Item 1	Item 2	Support	Confidence	Lift
0	(minyak)	(beras)	0.409836	0.806452	1.446869
1	(garam)	(odol gigi)	0.393443	0.800000	1.478788
3	(minyak, sikat gigi)	(beras)	0.311475	1.000000	1.794118
4	(beras, sikat gigi)	(minyak)	0.311475	0.863636	1.699413

Pada tabel 5 menampilkan dari hasil perintah *python* kita buat hasil mencari minimum *lift* pada *frequent 2-Itemset* yang sudah dicari nilai *support*nya menjadi tabel sesuai dengan hasil yang didapatkan.

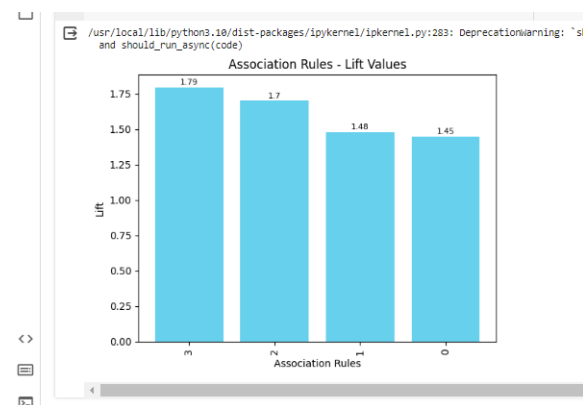
4.1.6. Hasil

Setelah ditahap evaluasi dilakukan hasil visualisasi data untuk menampilkan nilai *lift* dari setiap aturan yang telah dihitung.

```
import matplotlib.pyplot as plt
# Sorting rules berdasarkan nilai lift secara descending
sorted_rules = rules.sort_values(by='lift', ascending=False)
# Membuat diagram batang untuk aturan asosiasi
plt.bar(range(len(sorted_rules)), sorted_rules['lift'], align='center', color='skyblue')
plt.xticks(range(len(sorted_rules)), sorted_rules.index, rotation=90)
plt.xlabel('Association Rules')
plt.ylabel('Lift')
plt.title('Association Rules - Lift Values')
# Menambahkan label untuk setiap batang
for i, v in enumerate(sorted_rules['lift']):
    plt.text(i, v + 0.05, round(v, 2), ha='center', va='bottom', fontsize=8)
plt.show()
```

Gambar 16. Mencari visualisasi data

Berdasarkan gambar 16 menampilkan proses *python* untuk mencari hasil visualisasi data dari nilai *lift* yang telah dihitung.



Gambar 17. Visualisasi Data

Berdasarkan gambar 17 menampilkan hasil visualisasi diagram batang. Setiap batang pada diagram mewakili satu aturan asosiasi ,dengan tinggi batang yang mencerminkan nilai *lift* dari aturan asosiasi tersebut. Diagram pada gambar 17 diurutkan secara *descending* berdasarkan *lift*, sehingga aturan dengan nilai *lift* tertinggi terletak di bagian paling atas. Untuk menguji hasil penelitian ini digunakan nilai minimum Support 30% dan nilai Confidence 80% serta tahap evaluasi menggunakan *lift ratio* minimum 100% dari hasil pengujian tersebut terdapat beberapa yang memenuhi syarat aturan asosiasi. Misalnya kombinasi,

minyak dan beras yang memiliki nilai Support 40%, nilai Confidence 30% dan nilai lift ratio 1,44. Implikasi dari hasil penemuan pola pembelian ini bisa dijadikan strategi penjualan Contohnya, saran untuk penempatan produk, promo khusus untuk produk dan manajemen stok yang efisien.

5. KESIMPULAN DAN SARAN

Berdasarkan hasil penelitian tersebut, terdapat beberapa kesimpulan yang dapat ditarik. Pertama, penggunaan algoritma Apriori mampu membentuk pola kombinasi itemset yang berguna sebagai panduan dalam penyusunan data transaksi. Pola kombinasi ini memberikan wawasan yang berharga dalam memahami perilaku konsumen dan preferensi produk. Kedua, aturan asosiasi yang dihasilkan oleh teknik association rule memberikan gambaran yang jelas tentang hubungan antar item produk dalam sebuah kombinasi itemset, memungkinkan untuk mengidentifikasi asosiasi yang kuat antara produk tertentu.

Untuk pengembangan selanjutnya, direkomendasikan untuk menjelajahi algoritma lain seperti ECLAT atau FP-Growth dalam analisis association rules. Membandingkan hasil dari ketiga algoritma tersebut dapat memberikan pemahaman yang lebih mendalam tentang kelebihan dan kekurangan masing-masing metode, serta memungkinkan untuk memilih pendekatan yang paling efektif sesuai dengan kebutuhan penelitian. Dengan demikian, penelitian masa depan diharapkan dapat memberikan kontribusi yang lebih besar dalam pemahaman tentang pola pembelian dan hubungan antar produk dalam transaksi konsumen.

DAFTAR PUSTAKA

- [1] S. S. R. D. K. M. R. Septiadi3, "IMPLEMENTASI ANALISIS KERANJANG BELANJA DENGAN ATURAN ASOSIASI MENGGUNAKAN ALGORITMA APRIORI PADA PENJUALAN SUKU CADANG MOTOR Abstrak," vol. 6, no. 2, pp. 270–278, 2023.
- [2] I. M. D. P. A. A.A. Gede Bagus Ariana, "Analisis Keranjang Belanja Dengan Algoritma Apriori Pada Perusahaan Retail," *Semin. Nas. Sist. Inf. Indones.*, pp. 2–4, 2013.
- [3] K. Darmaastawan, "Analisis Keranjang Belanja Menggunakan Algoritma Apriori untuk Menentukan Tata Letak Barang (Studi Kasus: Apotek Mooladhara Denpasar) Kadek," *G-Tech J. Teknol. Terap.*, vol. 7, no. 2, pp. 637–8737, 2022, [Online]. Available: <https://ejournal.uniramalang.ac.id/index.php/g-tech/article/view/1823/1229>
- [4] Amna, W. S, I. G. I. S. T. A. E. Putra, A. J. W. W. A. Syukrilla, A. K. W. N. H. T. Indriyani, and L. W. Santoso, *Data Mining Data mining*, vol. 2, no. January 2013. 2023. [Online]. Available: https://www.cambridge.org/core/product/identifier/CBO9781139058452A007/type/book_part
- [5] N. FEBRIANTI, "II-1 BAB II LANDASAN TEORI 2.1. Analisis Asosiasi (Association Rule Mining)," pp. 1–25, 2021.
- [6] Amrin Amrin, "Data Mining Dengan Algoritma Apriori untuk Penentuan Aturan Asosiasi Pola Pembelian Pupuk," *Paradigma*, vol. XIX, no. 1, pp. 74–79, 2017, doi: <https://doi.org/10.31294/p.v19i1.1836>.