

BAB II

TINJAUAN PUSTAKA

2.1 Teori dasar


Pemahaman tentang *Knowledge Discovery in Database* (KDD), teknik Data Mining, penerapan Algoritma *FP-Growth*, dan analisis dan penjelasan adalah beberapa komponen yang mendukung penyelesaian topik ini. Program tambahan seperti RapidMiner.

2.1.1 *Knowledge Discovery In Database* (KDD)

Knowledge Database adalah bagian penting dari sistem informasi manajemen, yang berfungsi sebagai repositori terintegrasi untuk menyimpan, mengelola, dan mengolah berbagai jenis data dan informasi. Informasi ini kemudian diubah menjadi pengetahuan untuk membantu proses pengambilan keputusan dan meningkatkan kinerja operasional. Pengembangan *Knowledge Database* untuk sistem informasi manajemen akademik di era digital saat ini

Digital saat ini membutuhkan penggunaan teknologi terbaru seperti arsitektur modular dan *platform* berbasis *cloud*. Ini memungkinkan integrasi data dari berbagai sumber secara *real-time* dan pembaruan otomatis untuk menjaga relevansi data dengan dinamika kebutuhan pengguna. Ini menunjukkan bahwa pergeseran proses pengelolaan data dari metode manual ke sistem digital terintegrasi tidak hanya meningkatkan efisiensi operasional tetapi juga meningkatkan validitas data melalui mekanisme rekonsiliasi dan verifikasi yang sistematis, yang menghasilkan basis pengetahuan yang adaptif untuk berbagai jenis data. Oleh karena itu, proses optimalisasi *Knowledge Database* berfungsi sebagai

dasar untuk pengelolaan informasi akademik yang efisien serta sebagai dasar untuk kebijakan strategis organisasi di bidang pendidikan (Syachbana & Huda, n.d. 2022).



Gambar 2. 1 KDD

KDD dijalankan melalui serangkaian tahapan sistematis. Setiap tahap memiliki peran penting dalam memastikan hasil akhir benar-benar merepresentasikan pola yang berguna dan dapat dipercaya. Berikut ini adalah tahapan-tahapannya:

1. *Selection*: Dimulai dengan memilih kumpulan data yang relevan dari berbagai sumber. Karena tidak semua data akan digunakan, peneliti harus menentukan mana yang paling cocok untuk dianalisis. Untuk mendapatkan hasil yang diinginkan, tahap ini, seperti memilih bahan utama sebelum memasak, sangat penting.
2. *Preprocessing*: Sering kali, kesalahan seperti data yang hilang, tidak konsisten, atau duplikat ditemukan saat data dikumpulkan. Oleh karena itu, langkah ini berkonsentrasi pada penyusunan ulang dan pembersihan agar data siap untuk analisis. Sebelum memulai memasak, ini dianggap sebagai tahap merapikan dapur.
3. *Transformation*: Pada tahap ini, data yang sudah bersih disusun ulang atau diubah ke dalam format yang lebih cocok untuk proses penambangan data.

Misalnya, data dapat diskalakan, dikodekan ulang, atau diintegrasikan dengan data lain agar lebih mudah dianalisis.

4. *Data Mining*: Inilah inti dari KDD, di mana berbagai teknik statistik, Algoritma pengajaran mesin, atau metode kecerdasan buatan digunakan untuk menemukan pola atau informasi tersembunyi dalam data. Teknik dapat disesuaikan untuk berbagai tujuan, seperti klasifikasi, klastering, prediksi, atau asosiasi.
5. *Interpretation & Evaluation*: Hasil yang diperoleh dari proses penambangan data tidak selalu memiliki manfaat langsung. Akibatnya, langkah ini sangat penting untuk menentukan apakah model atau pola yang ditemukan benar-benar relevan dan dapat digunakan. Selain itu, visualisasi dan interpretasi dilakukan di sini untuk membuat hasil mudah dipahami oleh pemangku kepentingan.
6. *Knowledge Application*: Meskipun sering terabaikan, tahap akhir ini sangat penting. Pengetahuan harus diterapkan dalam kehidupan nyata, bukan hanya ditemukan. Misalnya, dapat digunakan untuk membantu proses pengambilan keputusan strategis, meningkatkan efisiensi operasional, atau membangun sistem berbasis data yang dapat disesuaikan. Siklus KDD menjadi nyata di sini karena pengetahuan ini benar-benar memberikan nilai dan efek pada sistem atau organisasi.

2.1.2 E-commerce

Perdagangan elektronik, juga dikenal sebagai e-commerce, adalah proses pembelian, penjualan, atau pertukaran barang dan jasa melalui jaringan komputer seperti Internet. Transaksi dapat terjadi dalam berbagai bentuk, termasuk penjualan

langsung melalui aplikasi web dan ponsel, pasar digital, dan sistem pendukung seperti logistik dan pembayaran elektronik E-Commerce tidak hanya mencakup jual-beli, tetapi juga kolaborasi mitra bisnis sebagai bagian dari ekosistem e-business yang lebih luas.

Meningkatnya akses internet dan penggunaan smartphone mendorong pertumbuhan e-Commerce di Indonesia. menemukan bahwa e-commerce tidak hanya membuat jual beli lebih mudah, tetapi juga memiliki kemampuan untuk meningkatkan daya saing usaha kecil dan menengah karena memungkinkan mereka mengakses pasar di mana pun dan kapan pun. Selain itu, e-Commerce memainkan peran penting dalam mengubah pola konsumsi masyarakat menjadi lebih praktis dan efisien. Oleh karena itu, para pelaku usaha harus tahu cara mengelola data transaksi untuk membuat strategi pemasaran yang sesuai dengan kebutuhan konsumen.(Sugeng, 2020)

2.1.3 Data Mining

Data mining adalah proses menambang pengetahuan dari kumpulan data yang sangat besar. Ini juga dapat didefinisikan sebagai proses mengekstraksi data yang tidak diketahui untuk kemudian dapat diverifikasi untuk mengekstrak informasi bermanfaat. Proses ini biasanya didefinisikan sebagai proses yang mencari pola-pola yang belum diketahui dari data yang ada untuk menemukan pengetahuan yang belum diketahui dari data yang tersimpan (Handoko et al., 2023)

Data mining adalah proses pengumpulan informasi penting dari sejumlah besar data untuk diproses kemudian untuk menghasilkan informasi berguna dan

pola yang terbentuk dalam data. Proses ini biasanya menggunakan metode matematika, statistika, atau AI. Beberapa metode pengolahan data menggunakan data mining termasuk klasifikasi, asosiasi, klustering, regresi, prediksi, urutan, dan deskriptif. Data mining digunakan untuk menjelaskan kondisi penelitian, menjamin pernyataan atau memperkuat hipotesis, dan menemukan pola baru yang sebelumnya tidak terdeteksi (Simajuntak & Elisa, n.d. 2019).

Pengumpulan data, pembersihan data, pemrosesan data, dan penerapan Algoritma penambangan adalah komponen utama dari proses penambangan data. Klasifikasi, klustering, dan asosiasi adalah Algoritma data mining yang paling umum digunakan. Misalnya, dalam analisis kesehatan, metode klasifikasi seperti *Naïve Bayes* atau *Decision Tree* dapat digunakan untuk memprediksi risiko penyakit tertentu berdasarkan data pasien sebelumnya. Di sisi lain, dalam perekonomian, data mining dapat digunakan untuk melihat pola pembelian dan perilaku konsumen dengan menggunakan Algoritma seperti *Apriori* (David & Isa, n.d. 2021).

Tantangan data mining sangat besar, meskipun ada banyak manfaatnya. Salah satu masalah utama adalah masalah kualitas data, karena data yang buruk dapat menyebabkan hasil analisis yang salah. Oleh karena itu, sangat penting untuk mengikuti standar terbaik dalam pengolahan data, yang mencakup pemrosesan data yang tepat dan penggunaan metode pengolahan data yang tepat. Dalam hal penggunaan dan perlindungan data pribadi, aspek etika juga harus dipertimbangkan (Asward & Brotosaputro, 2021).

2.1.4 Algoritma *FP-Growth*

Frequent Pattern Growth (FP-Growth) adalah salah satu alternatif Algoritma yang dapat digunakan untuk menentukan himpunan data yang paling sering muncul *frequent itemset* dalam sebuah kumpulan data. Algoritma *FP-Growth* merupakan pengembangan dari Algoritma *Apriori*. Sehingga kekurangan dari Algoritma *Apriori* diperbaiki oleh Algoritma *FP-Growth*.

FP-Growth menggunakan konsep pembangunan *Tree* dalam pencarian *frequent itemsets*. Hal tersebutlah yang menyebabkan Algoritma *FP-Growth* lebih cepat dari Algoritma *Apriori*. Karakteristik Algoritma *FP-Growth* adalah struktur data yang digunakan adalah *Tree* yang disebut dengan *FP-Tree*. Dengan menggunakan *FP-Tree*, Algoritma *FP-Growth* dapat langsung mengekstrak *frequent itemset* dari *FP-Tree* (Anggrawan et al., 2021).

FP-Tree merupakan struktur penyimpanan data yang dimampatkan. *FP-Tree* dibangun dengan memetakan setiap data transaksi ke dalam setiap lintasan tertentu dalam *FP-Tree*. Karena dalam setiap transaksi yang dipetakan, mungkin ada transaksi yang memiliki item yang sama, maka lintasannya memungkinkan untuk saling menimpa. Semakin banyak data transaksi yang memiliki item yang sama, maka proses pemampatan dengan struktur data *FP-Tree* semakin efektif. Penggalan *itemset* yang *frequent* dengan menggunakan Algoritma *FP-Growth* akan dilakukan dengan cara membangkitkan struktur data *Tree (FP-Tree)*. Metode *FP-Growth* dapat dibagi menjadi 3 tahapan utama yaitu sebagai berikut :

1. Tahap Pembangkitan *Conditional Pattern Base Conditional Pattern Base* merupakan subdatabase yang berisi *prefix path* lintasan *prefix* dan *suffix pattern*

pola akhiran. Pembangkitan *Conditional Pattern Base* didapatkan melalui *FP-Tree* yang telah dibangun sebelumnya.

2. Tahap pebangkitan *Conditional FP-Tree* Pada tahap ini, *support* count dari setiap item pada setiap *Conditional Pattern Base* dijumlahkan, lalu setiap item yang memiliki jumlah *support* count lebih besar sama dengan *minimum support* count akan dibangkitkan dengan *Conditional FP-Tree*.
3. Tahap pencarian *frequent itemset* Apabila *Conditional FP-Tree* merupakan lintasan tunggal *single path*, maka didapatkan *frequent itemset* dengan melakukan kombinasi item untuk setiap *Conditional FP-Tree*. Jika bukan lintasan tunggal, maka dilakukan pembangkitan *FP-Growth* secara rekursif.

2.1.4.1 Aturan asosiasi

Metode data mining yang dikenal sebagai aturan asosiasi digunakan untuk mengidentifikasi hubungan atau keterkaitan antara item dalam kumpulan data. Tujuan utama dari aturan asosiasi adalah untuk mengidentifikasi pola hubungan yang sering terjadi antara item-item dalam transaksi. Aturan ini pertama kali digunakan dalam analisis keranjang belanja untuk mengidentifikasi bagaimana pelanggan melakukan pembelian di toko ritel. Aturan asosiasi menggunakan tiga metrik utama untuk mengukur kekuatan hubungan antara item yaitu:

1. *Support* mengukur seberapa sering kombinasi item muncul dalam dataset transaksi. Rumusnya adalah:

$$\text{Support } (X \rightarrow Y) = \frac{\text{Jumlah transaksi yang mengandung (X dan Y)}}{\text{Total jumlah transaksi}}$$

Rumus 2. 1 Nilai *Support*

2. *Confidence* mengukur seberapa sering item Y muncul dalam transaksi yang sudah mengandung item X. Rumusnya adalah:

$$\text{Confidence } (X \rightarrow Y) = \frac{\text{Jumlah transaksi yang mengandung (X dan Y)}}{\text{Jumlah transaksi yang mengandung (X)}}$$

Rumus 2. 2 Nilai *Confidence*

2.1.5 RapidMiner

RapidMiner adalah sebuah *platform* perangkat lunak *open-source* yang digunakan untuk *data science*, *machine learning*, dan analisis prediktif. *Platform* ini menyediakan antarmuka grafis berbasis *drag-and-drop*, yang memungkinkan pengguna merancang dan mengeksekusi proses analisis data secara visual tanpa harus menulis kode secara langsung. RapidMiner sangat populer dalam dunia akademik dan industri karena kemudahan penggunaannya dan fleksibilitasnya dalam mengelola data besar serta membangun model analisis kompleks. RapidMiner mendukung hampir seluruh proses dalam alur data mining, yang secara umum meliputi:

1. **Preprocessing:** Pembersihan, transformasi, dan normalisasi data.
2. **Modeling:** Penerapan Algoritma seperti *FP-Growth*, *Decision Tree*, *Naïve Bayes*, dan lainnya.
3. **Evaluation:** Pengukuran performa model menggunakan metrik seperti *accuracy*, *precision*, *recall*, dan *confusion matrix*.
4. **Deployment:** Implementasi hasil analisis ke sistem nyata atau untuk keperluan bisnis.

Dalam konteks penelitian, RapidMiner sangat berguna untuk membantu eksplorasi dan analisis data dalam berbagai bidang seperti keuangan, kesehatan,

pemasaran, dan pendidikan. *Platform* ini juga memungkinkan pengguna untuk menyusun alur kerja *process* yang kompleks secara modular, memudahkan dokumentasi dan replikasi penelitian.

Dengan semua fitur tersebut, RapidMiner menjadi salah satu tools utama dalam pelaksanaan proyek data mining dan menjadi alternatif populer selain bahasa



pemrograman seperti Python, khususnya bagi pengguna yang menginginkan pendekatan non-programming. (Agusstewan & Handoko, 2024)

Gambar 2. 2 RapidMiner

2.2 Penelitian terdahulu

Proses untuk melakukan penelitian ini, peneliti menggunakan penelitian sebelumnya sebagai referensi dan meningkatkan teori untuk meningkatkan penelitian. Karena Setelah itu, peneliti menampilkan hasil penelitian sebelumnya sebagai berikut:

1. (Muhammad Rizky Alditra Utama et al., 2020), *Determining Promotions at UD. Jakarta Pixel using Web-Based FP-Growth Association Model*. Jurnal DINAMIK, Vol. 2, No. 1, 2025 Selama periode enam bulan, penelitian ini menggunakan Algoritma *FP-Growth* untuk menganalisis data transaksi yang melibatkan penjualan produk elektronik di sebuah *platform e-commerce*. Hasil analisis menunjukkan pola pembelian yang signifikan, dengan keyakinan sebesar 83% dan dukungan sebesar 25%. Ini menunjukkan hubungan yang kuat

antara barang yang sering dibeli bersamaan. Untuk meningkatkan efektivitas penjualan, penelitian ini menyarankan penempatan produk yang saling berhubungan secara strategis dalam kampanye pemasaran dan promosi. Meskipun demikian, penelitian ini belum mengevaluasi secara langsung dampak penerapan strategi tersebut terhadap peningkatan omzet; oleh karena itu, ini mungkin merupakan topik yang dapat dieksplorasi lebih lanjut dalam studi <https://doi.org/10.24090/tids.v2i1.12208>.

2. (Djabalul Lael & Pramudito, 2023b), *Use of Data Mining for The Analysis of Consumer Purchase Patterns with The Fp-growth Algorithm on Motor Spare Part Sales Transactions Data* . Jurnal IAIC Transactions on Sustainable Digital Innovation, Vol. 4 No. 2 (2023). Hasil penelitian menunjukkan bahwa dengan menggunakan Algoritma *FP-Growth* untuk menganalisis data penjualan, dapat ditemukan kombinasi produk yang sering dibeli bersamaan dengan keyakinan sebesar 85% dan dukungan sebesar 30%. Data yang dianalisis berasal dari enam bulan penjualan di sebuah toko retail besar. Hasil ini memberikan dasar yang kuat untuk membuat strategi *Cross-Selling* yang lebih baik untuk meningkatkan penjualan dan loyalitas pelanggan. Namun, penelitian tersebut belum melihat secara langsung bagaimana menerapkan rekomendasi produk meningkatkan penjualan, jadi ada ruang untuk penelitian tambahan. <https://doi.org/10.34306/itsdi.v4i2.582>.
3. (Wandri & Hanafiah, 2022), *Analysis of Information Technology (IT) Goods Sales Patterns Using the FP-Growth Algorithm*, IT Journal Research and Development. Vol.6, No.2 (2022) Analisis ini menemukan pola pembelian yang

signifikan di *platform e-commerce* yang menggunakan Algoritma *FP-Growth*, yang menghasilkan keyakinan sebesar 80% dan dukungan sebesar 27%. Ini menawarkan wawasan berharga bagi manajer pemasaran untuk membuat strategi penempatan produk yang lebih baik, yang diharapkan dapat meningkatkan interaksi pelanggan dan mendorong peningkatan penjualan. Namun, penelitian ini belum melihat dampak langsung strategi penempatan produk terhadap penjualan dampak ini mungkin menjadi subjek penelitian lebih lanjut <https://doi.org/10.25299/itjrd.2022.8155>.

4. (Sudarto & Handoko, 2023), IMPLEMENTASI DATA MINING PADA PENGATURAN DATA INVOICE DISTRIBUTOR MENGGUNAKAN ALGORITMA FP GROWTH. Jurnal Comasie, Vol 9 No.2 (2023) Wyssa Artha Sejahtera adalah perusahaan distribusi yang tujuan penelitian ini adalah untuk menggunakan Algoritma FP Growth untuk membantu pengambilan keputusan dalam memproses data transaksi penjualan. Perusahaan ini melakukan banyak transaksi basah dan kering setiap hari. Tujuan dari penelitian ini adalah untuk menganalisis tren penjualan dan barang yang paling populer. Data dikumpulkan dari Januari hingga Desember 2022 melalui observasi dan wawancara langsung dengan pemilik perusahaan. *Itemset* 1, 2, 3, dan 4 dengan nilai *support* dan *Confidence* yang sesuai ditampilkan dalam hasil analisis menggunakan perangkat lunak RapidMiner. Diharapkan hasil ini akan membantu PT. Wyssa Artha Sejahtera membuat rencana penjualan yang lebih baik dan memenuhi permintaan pelanggan. Selain itu, Algoritma FP Growth dapat menjadi referensi yang bermanfaat bagi perusahaan lain yang bekerja dalam industri yang sama

<https://doi.org/10.33884/comasiejournal.v9i2.7603>.

5. (Lowensky & Elisa, 2023), ANALISA POLA PEMBELIAN KONSUMEN MENGGUNAKAN DATA MINING DENGAN ALGORITMA *APRIORI* (STUDI KASUS: EDUKITS BATAM CENTRE). Jurnal Comasie, Vol 9 No. 2 (2023) Metode yang digunakan adalah Algoritma asosiasi *Apriori* dengan analisis nilai *support* dan *Confidence*. Hasil penelitian menunjukkan nilai *support* untuk kategori Kertas Print 71%, Aksesori 74%, Peralatan Lainnya 88%, dan Lem/Perekat 72%. Dua aturan yang ditemukan adalah: pertama, jika membeli alat tulis, kemungkinan besar akan membeli aksesori dengan *support* 65% dan *Confidence* 84,4%. Kedua, jika membeli aksesori, kemungkinan besar akan membeli alat tulis dengan *support* 65% dan *Confidence* 88,4%

<https://doi.org/10.33884/comasiejournal.v9i2.7608>.

6. (Eko Saputro, 2025) *Application of the FP-Growth Algorithm to Determine Sales Patterns at Najah Mart*. CSRID Journal, Vol 17 No.1 (2025) Hasil analisis menunjukkan bahwa Algoritma *FP-Growth* memiliki kemampuan untuk menghasilkan aturan asosiasi dengan nilai dukungan sebesar 20% dan kepercayaan sebesar 82%. Penelitian ini menggunakan data transaksi pelanggan selama periode tertentu untuk menemukan pola pembelian yang konsisten. Hasil ini memberikan dasar yang kuat untuk membangun rekomendasi produk yang relevan yang didasarkan pada perilaku pembelian pelanggan. Rekomendasi ini dapat dimasukkan ke dalam strategi pemasaran yang lebih terarah dan efektif. Namun, studi ini belum melihat secara langsung bagaimana

penerapan rekomendasi produk meningkatkan penjualan. Hal ini dapat menjadi subjek penelitian tambahan <https://doi.org/10.22303/csrid-.17.1.2025.1-19>.

7. (Aziz Sahidin & Hayati, 2024), ANALISIS DATA MINING DALAM MENENTUKAN STRATEGI PENJUALAN TERHADAP POLA PEMBELIAN PADA PENJUALAN PRODUK SHAKA VAPORSHOP MENGGUNAKAN ALGORITMA *FP-GROWTH*, Jurnal Mahasiswa Teknik Informatika, Vol. 8 No 1,(2024) Dalam penelitian ini, Algoritma *FP-Growth* menemukan kombinasi produk yang sering dibeli dengan nilai dukungan sebesar 31% dan kepercayaan sebesar 82%. Penemuan ini menunjukkan bahwa strategi pemasaran yang didasarkan pada analisis pola penjualan pelanggan mungkin lebih terarah dan efektif. Bisnis dapat meningkatkan penjualan dan meningkatkan kampanye promosi dengan memanfaatkan informasi ini. Namun, penelitian ini belum melihat efek langsung dari penerapan strategi tersebut terhadap peningkatan performa penjualan, jadi ada ruang untuk studi lebih lanjut <https://doi.org/10.36040/jati.v8i1.8782>.
8. (Hany Talia et al., 2024), PENERAPAN ALGORITMA *FP-GROWTH* DALAM ANALISIS POLA TRANSAKSI UNTUK OPTIMALISASI PENGELOLAAN DATA TRANSAKSI DI TOKO LIA, Jurnal Kecerdasan Buatan dan Teknologi Informasi, Vol. 3, No. 1 tahun 2024 Hasil penelitian ini menunjukkan bagaimana Algoritma *FP-Growth* digunakan untuk menemukan kumpulan barang sering dibeli dari data penjualan toko Lia. Hasil menunjukkan bahwa kombinasi produk seperti roti dan minuman memiliki dukungan sebesar 70% dan keyakinan sebesar 85%, yang menunjukkan bahwa mereka memiliki


potensi besar untuk digunakan sebagai paket promosi. Ini meningkatkan strategi penjualan dan pengelolaan stok <https://doi.org/10.69916/jkbt.v3i1.108>.

9. (Shihab & Fatah, 2023), Implementasi Algoritma *FP-Growth* Pada Dataset Sintetis Untuk Penentuan Pola Pembelian Sembako Dan Kebutuhan Harian, Jurnal Ilmiah Multidisiplin Nusantara, Vol No 3 tahun 2024, Dataset sintetis digunakan dalam studi ini untuk mensimulasikan pola pembelian sembako. Item sering seperti "beras + minyak goreng" memiliki keyakinan tinggi dengan dukungan *minimum* 78% dan keyakinan 88%. Dengan kata lain, hampir 9 dari 10 transaksi yang membeli beras juga melibatkan minyak goreng. Peneliti menunjukkan bahwa *FP-Growth* sangat efektif bahkan ketika dataset nyata dibangun. Hasilnya langsung dapat diterapkan sebagai metode bundling dalam penjualan sembako ritel <https://doi.org/10.59435/jimnu.v2i3.452>.
10. (Rustam et al., 2024), Penerapan Data Mining Menggunakan Algoritma *FP-Growth* dalam Analisis Data Penjualan, Jurnal KomtekInfo, Vol 11 no 4 Tahun 2024, Dalam penelitian yang dilakukan oleh Camila Rustam et al. (2024), Algoritma *FP-Growth* digunakan untuk mempelajari pola pembelian produk makanan dan minuman ringan. Aturan seperti "jika membeli Spix Mie Goreng 500, maka kemungkinan besar juga membeli Golda" dengan keyakinan 82% ditemukan dengan dukungan *minimum* 75% dan keyakinan 80%. Pola ini menunjukkan bahwa tiga dari empat orang yang membeli mie goreng juga membeli minuman tersebut. Hasil ini menunjukkan bahwa *FP-Growth* efektif dalam analisis penjualan ritel, serta bermanfaat untuk strategi bundling, penempatan produk, dan pengelolaan stok.

<https://doi.org/10.35134/komtekinfo.v1i14.547>

2.3 Kerangka pemikiran

Berikut ini adalah kerangka kerja yang dibuat untuk menjelaskan penelitian yang dilakukan:



Gambar 2. 3 Kerangka pemikiran

Pada langkah awal penelitian, proses pengumpulan data input terdiri dari informasi tentang produk atau barang, seperti merek dan jenis produk, serta jumlah total transaksi, yang telah selesai. Sebelum diproses oleh Algoritma, data disaring dengan mempertimbangkan nilai *Support minimum* dan *Confidence minimum*. Untuk memastikan bahwa hasil yang diperoleh akurat, langkah selanjutnya adalah pengujian data menggunakan program RapidMiner. Tujuan dari proses ini adalah untuk mengetahui barang apa yang paling sering dibeli oleh pelanggan. Toko yang ingin memahami pola penjualan dapat menggunakan informasi ini.