

## BAB 2 TINJAUAN PUSTAKA

### 2.1. Penelitian Terdahulu

Penelitian terdahulu ini membahas tentang penelitian-penelitian yang telah mereka lakukan terkait dengan perilaku konsumen dengan perusahaan *e-commerce*. Daftar jurnal yang digunakan sebagai pendukung penelitian dapat dilihat dalam Tabel 2.1

**Tabel 2.1. Tabel Penelitian Terdahulu**

Referensi	Komponen					
	Business Intelligence	Create Model	Association Rule	Framework	Forecasting	Dashboard
Ahakhatreh (2022)	✓					
Alghanam et al (2022)		✓				
Alhoukari (2017)	✓					
Alwidian et al (2018)			✓			
Arivukarasi (2019)	✓					
Atsani (2019)	✓					
Bach (2017)	✓	✓				
Bach et al (2017)	✓	✓				
Balachandran (2017)	✓					
Bany Mohammad (2022)	✓			✓		
Bousqaoui et al (2021)		✓			✓	
Combita (2020)	✓			✓		
Dahooei (2018)	✓					
Demisse (2017)						
Dhariwal et al (2017)	✓	✓	✓			
Dhyani et al (2020)					✓	
Ehie (2019)	✓			✓		
Ernawati dan Matondang (2021)		✓				✓
Fernandez et al (2017)						✓
Fitriana (2017)	✓					

Fitrianah (2021)						✓
Fu et al (2021)	✓					
Ghosh (2021)		✓			✓	
Ghosh Partha (2018)	✓					
Indah Prahartiwi (2017)	✓		✓			
Lee (2022)	✓					
Lourcenco dan Varde (2020)		✓	✓			
Massaro et al (2019)						
Mikhnenko (2022)		✓				
Naenini(2019)	✓					
Nasir (2021)	✓					
Ozturk (2018)					✓	
Parikh et al (2015)		✓	✓	✓		
Ramos (2017)	✓			✓		
Rao et al (2018)			✓			
Rezaie (2017)	✓					
Riyadi et al (2019)			✓			
Robu et al (2019)		✓	✓			
Sahai et al (2020)					✓	
Setehel (2021)	✓					
Sharma dan Ganpati (2021)			✓			
Silvana (2017)	✓					
Souibgui et al (2019)		✓				
Srinadh (2022)			✓			
Tauscher et al (2018)		✓				
Wang et al (2018)			✓			
Yafang dan Yisong (2018)		✓	✓			
Zhang (2021)	✓			✓		
Zhou et al (2021)		✓				✓

Pada penelitian – penelitian terdahulu ini telah melakukan penelitian terhadap perilaku konsumen dengan *e-commerce* dengan berbagai aspek, seperti mengembangkan teknologi dan kerangka kerja BI, membangun model, mengintegrasikan data, melakukan data mining, menggunakan association rule serta membuat *dashboard* dan *platform*. Pertama dalam mengembangkan teknologi BI dalam membuat *framework*, (Zhang et al., (2021) menyebutkan bahwa

kerangka kerja ini bersifat universal dan dapat diterapkan di berbagai jenis sistem rantai pasok. sistem rantai pasokan diuraikan menjadi blok standar terpadu yang mempersiapkan adopsi kembar digital. Selanjutnya, gagasan model referensi operasi rantai pasokan diadopsi untuk mendigitalkan aktivitas rantai pasokan dasar dalam setiap blok dan menjelaskan cara menggunakan sistem informasi yang ada tiga jurnal berbeda mengusulkan kerangka kerja konseptual untuk meningkatkan efisiensi dan ketangkasan operasi bisnis melalui teknologi digital dan analitik data. Makalah pertama berfokus pada digitalisasi manajemen rantai pasokan, sedangkan makalah kedua membahas penerapan kerangka kerja tata kelola intelijen bisnis di lingkungan universitas.

Makalah ketiga mengusulkan kerangka kerja untuk merancang kembaran digital dari rantai pasokan menggunakan model Referensi Operasi Rantai Pasokan dan pendekatan sistem sistem (Mohammad et al., 2022; Ehie & Ferreira, 2019; Ramos et al., 2017). Pengembangan dan implementasi Business Intelligence Governance Framework dalam konteks universitas, khususnya Universidad de la Costa. Kerangka tersebut mencakup seperangkat pedoman, kebijakan, dan prosedur untuk memastikan pengelolaan sistem BI universitas yang efektif dan efisien dan untuk mendukung proses pengambilan keputusan (Combita Niño et al., 2020).

Dalam membangun model, Fitriana et al., (2017) menyebutkan membangun sebuah model untuk menganalisis pola pembelian konsumen dapat menggunakan algoritma FP-Growth, hasil analisisnya menunjukkan adanya pola pembelian produk yang sering dibeli bersamaan oleh konsumen, perusahaan dapat menggunakan informasi ini untuk menentukan produk-produk mana yang sebaiknya ditampilkan bersama-sama pada satu tempat atau produk apa yang dapat ditawarkan sebagai *bundling*. Pentingnya analisis data dan business intelligence dalam meningkatkan kinerja bisnis. Ini menyoroti peran berbagai kerangka kerja yang diusulkan dalam berbagai studi (Ahakhatreh & Al-Hawary, 2022; Naeini et al., 2019; Atsani et al., 2019; Arivukarasi & Antonidoss, 2019). Kerangka kerja ini memungkinkan organisasi untuk memanfaatkan data mereka dan membuat keputusan berdasarkan informasi, yang pada akhirnya mengarah pada peningkatan efisiensi dan keunggulan kompetitif (Rezaie et al., 2017; Lee & Mangalaraj, 2022; Stehel et al., 2021).

Dalam mengintegrasikan data untuk pengembangan *business intelligence*, penting untuk mempertimbangkan integrasi data dari berbagai sumber yang relevan dengan tujuan bisnis yang ditetapkan. Selain itu, memahami bagaimana pengguna melihat nilai dari sistem *business intelligence* juga penting dalam memastikan adopsi dan penggunaan yang optimal (Alnoukari & Hanano, 2017; Bach et al., 2017; Nasir et al., 2021). Pengembangan model atau algoritma untuk mengintegrasikan data dalam rangka meningkatkan kinerja bisnis seperti pengembangan *business intelligence* dengan menganalisis sentimen pelanggan, pengembangan model evaluasi *business intelligence* untuk sistem enterprise, pengembangan model *business intelligence* untuk meningkatkan mutu layanan, dan pengembangan algoritma order batching pada era big data menggunakan association rule mining. Dalam hal ini, integrasi data dari berbagai sumber digunakan untuk memperoleh informasi yang lebih lengkap dan akurat untuk pengambilan keputusan bisnis yang lebih baik (Ghosh Partha et al., 2018; Dahoei et al., 2018; Silvana & Akbar, 2017; Bach et al., 2017; Balachandran & Prasad, 2017; Fu et al., 2021). Dalam hal melakukan data mining, penerapan data mining dalam berbagai bidang dapat dilakukan, tergantung penggunaan data mining seperti untuk memilih atribut penting penggunaan data mining, atau sebagai alat analisis bisnis multimodal dan juga dapat sebagai penggunaan algoritma data mining dan sistem big data dalam meningkatkan kinerja business intelligence di penelitian industri. Sehingga penggunaan *data mining* dalam menganalisis data dapat mengambil keputusan yang lebih baik dalam berbagai bidang (B. Demisse et al., 2017; Mikhnenko, 2022; Massaro et al., 2019). Souibgui et al., (2019) mengatakan proses yang penting dalam pengolahan data itu melibatkan ekstraksi, transformasi, dan pemrosesan data dari berbagai sumber untuk digunakan dalam analisis dan aplikasi bisnis.

Dalam penerapan teknik *association rule*, membangun model dapat meningkatkan performa bisnis dan pengalaman pelanggan di platform *e-commerce* serta tentang penggunaan algoritma *association rule mining* dan *clustering* untuk merekomendasikan produk kepada pelanggan (Alghanam et al., 2022; Parikh et al., 2015; Täuscher & Laudien, 2018). Dhariwal et al., (2017) menyebutkan bahwa pengembangan sebuah model untuk analisis data melalui *platform* berbasis web mencakup berbagai teknik statistik dan visualisasi yang memungkinkan para peneliti untuk melakukan analisis meta dan integratif data dari berbagai sumber. Dalam pengembangannya, model ini melibatkan integrasi dari

beberapa algoritma analisis data dan teknologi canggih lainnya untuk meningkatkan keakuratan dan efisiensi analisis. Dalam Algoritma Association Rule digunakan untuk memberikan rekomendasi produk dalam *e-commerce*, *association rule mining* untuk memproses pesanan secara efisien dan penggunaan *big data mining* dan *machine learning* untuk *referral service* di *e-commerce* (Lourenco & Varde, 2020; Y Li & Y Li, 2018; Riyadi et al., 2019; H Rao et al., 2018). Son et al., (2018) menyebutkan bahwa pentingnya algoritma association rule dalam mengoptimalkan pengalaman pengguna di platform *e-commerce*. Algoritma association rule mining dapat digunakan dalam berbagai konteks, seperti *e-commerce*, klasifikasi penyakit, dan konsumsi listrik rumah tangga, serta mencakup berbagai jenis algoritma association rule, seperti Apriori, Eclat, dan FP-Growth, yang memiliki efisiensi dan tujuan yang berbeda-beda. Algoritma *association rule mining* sangat penting dalam bidang *data mining* karena dapat membantu dalam menemukan hubungan dan pola di antara item-item dalam suatu data set (Wang et al., 2018; Alwidian et al., 2018; Prahartiwi, 2017). Algoritma *Association Rule* seperti Apriori, FP-Growth dan Eclat dapat menemukan hubungan dan pola di antara item-item dalam dataset transaksi besar, di mana evaluasi dilakukan dengan mempertimbangkan faktor-faktor seperti jumlah transaksi, minimum *support*, penggunaan memori dan waktu eksekusi serta setiap algoritma memiliki kinerja dan efektivitas yang berbeda dalam menangani data set yang besar (Sharma & Ganpati, 2021; Robu et al., 2019; Srinadh, 2022).

Wang et al., (2018) menyebutkan ARM adalah alat populer untuk mengidentifikasi korelasi menarik antar elemen dalam kumpulan data. Untuk mengidentifikasi hubungan asosiasi antara berbagai transaksi dalam database transaksional Boolean yang cukup besar. Format aturan asosiasi adalah  $\rightarrow AB$ , dimana kumpulan item disebut sebagai konsekuensi aturan (RHS) dan himpunan item disebut sebagai anteseden aturan (LHS) di sebelah kanan. Menurut aturan ini, dimungkinkan untuk memperkirakan kapan B akan terjadi berdasarkan kemunculan A.  $Supp(\|AB)$  mewakili persentase transaksi yang mengandung A dan B dalam keseluruhan rangkaian, yang mendukung aturan asosiasi.

Rumus untuk menghitung nilai support dari satu item adalah seperti berikut:

$$Support(A) = \frac{\sum Transaksi A}{\sum Transaksi} \times 100\% \quad (2.1)$$

Sedangkan untuk menghitung nilai support dari dua item atau lebih menggunakan rumus berikut:

$$\text{Support}(AB) = P(A \cap B) \quad (2.2)$$

$$\text{Support}(AB) = \frac{\sum \text{Transaksi } A \& B}{\sum \text{Transaksi}} \times 100\% \quad (2.3)$$

Nilai Support dari A dan B adalah jumlah keseluruhan transaksi yang mengandung item A dan B dibagi dengan total transaksi lalu dikali dengan 100 persen. Rumus untuk menghitung nilai minimum confidence dengan adalah seperti berikut:

$$\text{Confidence}(A \rightarrow B) = P(A|B) \quad (2.4)$$

$$\text{Confidence}(A \rightarrow B) = \frac{\sum \text{Transaksi } A \& B}{\sum \text{Transaksi } A} \times 100\% \quad (2.5)$$

Nilai confidence(A→B) atau Kepastian(A→B) diperoleh dengan membagi hasil nilai support dari A dan B dengan nilai support dari A dikali dengan 100 persen.

Dalam dashboard, pengembangan dengan software dalam bidang analisis data seperti aplikasi bundling produk yang mendukung implementasi algoritma association rule mining menggunakan FP-Growth, serta tentang Cluster Grammer, yaitu sebuah alat visualisasi dan analisis heatmap berbasis web untuk data biologi dengan dimensi yang tinggi. Kedua software ini dapat digunakan untuk mempermudah dan mempercepat analisis data dalam bidang masing-masing (Fernandez et al., 2017; Ernawati & Matondang, 2021). Serta platform digunakan untuk menganalisis data, dimana Omics Analyst adalah sebuah platform berbasis web yang menyediakan visualisasi dan analisis data multi-omics secara komprehensif. Sementara itu, algoritma FP-Growth untuk membangun model yang dapat menganalisis pola pembelian konsumen terhadap aksesoris handphone. Kedua platform ini memberikan kontribusi yang penting dalam pengembangan teknologi analisis data yang lebih efektif dan efisien (Zhou et al., 2021; Fitriyah & Zain, 2021).

Dalam peramalan, Box dan Jenkins menciptakan pendekatan ARIMA pada tahun 1970-an. Suatu model dilambangkan dengan ARIMA ( $p, d, q$ ) yang terdiri dari  $p$  adalah *autoregressive* model yang berisi jumlah *lag*,  $d$  adalah *degree of differencing* dimana terintegrasi mengacu pada langkah menghilangkan non stasioneritas dengan membedakan data atau terintegrasi dan  $q$  adalah moving

average model (Ghosh, 2021;Ozturk & Ozturk, 2018; Sahai et al., 2020;Dhyani et al., 2020).x

Bousqaoui et al., (2021) menyebutkan Model autoregresif AR(p) menyatakan bahwa variabel keluaran bergantung pada nilai sebelumnya dengan beberapa lag ditambah random term. Model autoregresif AR(p) didefinisikan sebagai:

$$y_t = A + \alpha_1 y_{t-1} + \alpha_2 y_{t-2} + \dots + \alpha_p y_{t-p} . \quad (2.6)$$

Dalam differencing, deret waktu disebut non stasioner jika nilai datanya bergantung pada waktu. Deret waktu yang tidak stasioner dapat diubah menjadi stasioner dengan membedakan deret waktu tersebut. Perbedaan mengacu pada pengurangan beberapa nilai data masa lalu beberapa kali. d degree of differencing mengacu pada berapa kali. Secara umum, suatu deret mungkin memerlukan diferensiasi pertama beberapa kali d untuk mencapai stasioneritas. Perbedaan derajat 1 adalah sebagai  $y_t' = y_t - y_{t-1}$

(2.7)

Dalam Moving Average Model, untuk mengatasi non-stasioneritas, kami mengkarakterisasi deret waktu sebagai jumlah dari nilai rata-rata non-konstan ditambah random error variable:  $x_t = \mu_t + \varepsilon_t$

(2.8)

Dalam metode smoothing, suatu variabel merupakan fungsi dari beberapa pengamatan di masa lalu, yang berarti bahwa nilai deret waktu di masa mendatang adalah rata-rata tertimbang dari beberapa pengamatan di masa lalu. Dengan demikian, rata-rata bergerak MA(q) berrorde q dapat ditulis sebagai nilai tertimbang rata-rata kesalahan q masa lalu.

$$y_t = B + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.9)$$

ARIMA adalah model campuran yang menggabungkan model autoregresif dan rata-rata bergerak yang berbeda. Bentuk akhir dari model deret waktu, yang bergantung pada p nilai masa lalunya dan pada nilai q masa lalu dari istilah kesalahan white noise, adalah sebagai berikut:

$$y_t = I + \alpha_1 y_{t-1}' + \alpha_2 y_{t-2}' + \dots + \alpha_p y_{t-p}' + \varepsilon_t + \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} \quad (2.10)$$

dengan  $y_t$  differenced to a degree d. Ini mewakili model ARIMA(p,d,q).

Dalam forecast accuracy matrix untuk ARIMA sama dengan yang digunakan di Exponential Smoothing yaitu :

$$\text{Root mean squared error: } RMSE = \sqrt{\text{mean}(\epsilon t^2)} \quad (2.11),$$

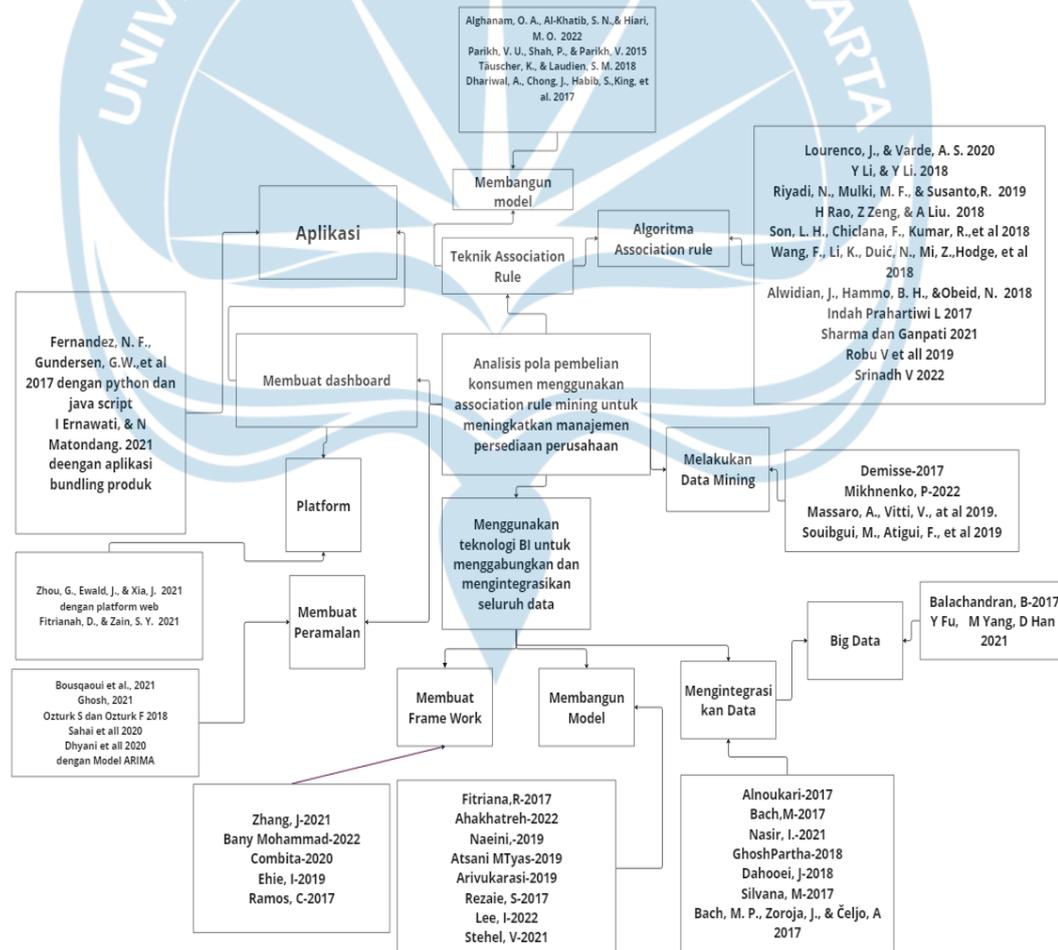
$$\text{Mean absolute error: } MAE = \text{mean}(|\epsilon t|) \quad (2.12),$$

$$\text{Mean absolute percentage error: } MAPE = \text{mean}\left(\left|\frac{100\epsilon t}{yt}\right|\right) \quad (2.13),$$

$$\text{Mean absolute scaled error: } MASE = \text{mean}(|\epsilon t|) / \text{scale} \quad (2.14).$$

## 2.2. Pengembangan Gap Penelitian

Kontribusi penelitian sebelumnya yang dilakukan antara tahun 2017 hingga 2022, dimana penelitian sebelumnya ini fokus pada analisis pola pembelian konsumen dan memiliki banyak keterkaitan dengan konten-konten terkait business intelligence, data mining, big data, dan e-commerce. Mind map dapat dilihat pada Gambar 2.1.



Gambar 2.1. Mind Map Penelitian Terdahulu

Penelitian tahun 2022 mulai menghubungkan topik ini dengan e-commerce, data mining, sistem business intelligence, dan association rule mining. Meskipun demikian, penelitian yang membahas e-commerce masih tergolong sedikit, dan pengaplikasian penerapannya juga terbatas. penelitian tentang analisis pola pembelian konsumen dalam beberapa tahun terakhir telah mencakup penggunaan data mining, big data, business intelligence, dan teknik asosiasi rule dalam konteks e-commerce. Meskipun demikian, penelitian sebelumnya belum pola perilaku konsumen dalam aplikasi langsung pada pengadaan persediaan, terutama dalam hal mengetahui item yang diproduksi sendiri atau bersama yang mempengaruhi efektivitas persediaan barang. Oleh karena itu, ada kebutuhan untuk mengembangkan penelitian yang dapat menggabungkan pola perilaku konsumen dengan manajemen persediaan untuk meningkatkan efisiensi dalam rantai pasokan.

Kontribusi baru dari penelitian ini adalah penerapan pola perilaku konsumen yang berhubungan langsung dengan pengadaan barang. Hal ini merupakan sebuah inovasi karena sebelumnya penelitian cenderung memusatkan perhatian pada analisis pola pembelian konsumen secara umum, namun belum secara spesifik mengaitkannya dengan pengelolaan persediaan barang. Dengan demikian, penelitian ini membuka peluang baru untuk memahami bagaimana perilaku konsumen secara langsung mempengaruhi keputusan pengadaan barang, yang pada gilirannya dapat meningkatkan efektivitas dan efisiensi dalam rantai pasokan.