




Análise do Comportamento do Consumidor com Business Intelligence

Catarina Filipa Vieira Pinheiro

24 / 2025



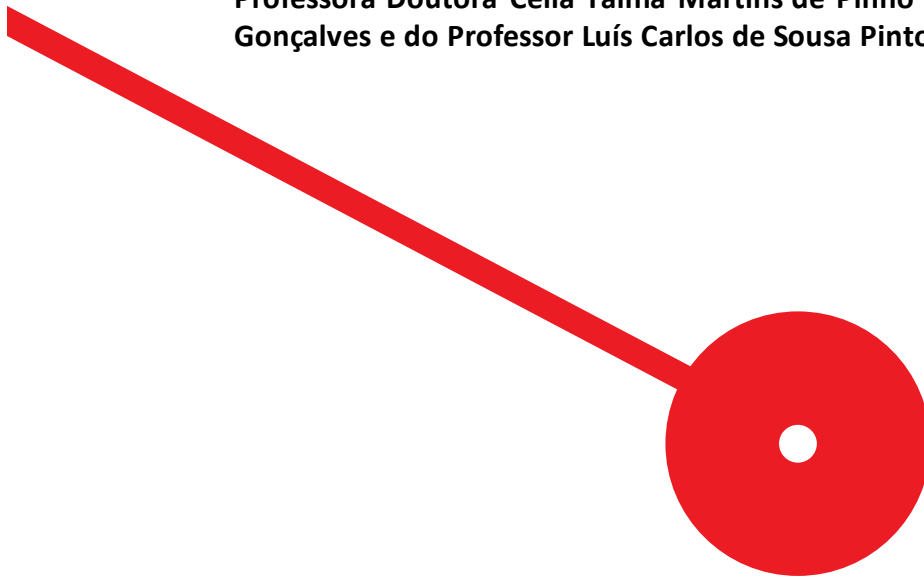
M

MESTRADO
BUSINESS INTELLIGENCE AND ANALYTICS

Análise do Comportamento do Consumidor com Business Intelligence

Catarina Filipa Vieira Pinheiro

Dissertação de Mestrado apresentada ao Instituto Superior de Contabilidade e Administração do Porto para a obtenção do grau de Mestre em Business Intelligence and Analytics sob orientação da Professora Doutora Célia Talma Martins de Pinho Valente Oliveira Gonçalves e do Professor Luís Carlos de Sousa Pinto



Resumo:

No contexto empresarial atual, em que a tomada de decisão depende cada vez mais da análise de dados, a capacidade de transformar informação em conhecimento estratégico tornou-se essencial para o crescimento e sustentabilidade das organizações. O *Business Intelligence* (BI) surge, assim, como um conjunto de práticas e tecnologias que permitem recolher, analisar e apresentar dados de forma útil para apoiar a tomada de decisões. Com o apoio de ferramentas analíticas, o BI permite transformar grandes volumes de dados em indicadores estratégicos (KPIs), ajudando as empresas a compreender melhor o seu desempenho e a antecipar mudanças no mercado.

O estudo e análise do comportamento do consumidor, tendo por base o uso de ferramentas de BI, constitui uma área fundamental para desenvolver estratégias de *marketing*, fidelizar clientes e melhorar o posicionamento da marca. Compreender os padrões de consumo, as preferências e as motivações dos clientes permite às empresas ajustar as suas ofertas, tornar as campanhas mais eficazes e tomar decisões mais acertadas.

Esta dissertação foca-se na aplicação do BI para a análise do comportamento dos consumidores. Para isso, foi criada uma solução de BI tendo por base um conjunto de dados sobre tendências de compras dos consumidores, disponível na *Web*. O objetivo principal é ilustrar como a análise de dados pode oferecer *insights* valiosos para as empresas, permitindo-lhes adaptar as suas ofertas, melhorar as suas campanhas de *marketing* e, conseqüentemente, otimizar o seu desempenho financeiro. Complementarmente, foi realizada uma análise bibliométrica com recurso ao *VOSviewer*, permitindo mapear as diferentes tendências e contribuições científicas na área do BI aplicado ao comportamento do consumidor.

Palavras chave: *business intelligence*; consumidor; segmentação; *power bi*

Abstract:

In today's data-driven business environment, being able to turn information into useful knowledge is key to helping companies succeed and stay competitive. Business Intelligence (BI) plays an important role in this process. It brings together tools, methods, and technologies that help collect, organize, analyze, and present data in a way that supports decision-making. With the help of analytical tools, BI turns large amounts of data into clear and practical insights, helping organizations understand their performance and identify market trends at an early stage.

Among the various areas of BI application, consumer behavior analysis stands out as an essential domain for developing marketing strategies, customer loyalty, and competitive positioning. A deep understanding of consumption patterns, customer preferences, and motivations enables companies to personalize offers, optimize campaigns, and enhance the effectiveness of business decisions.

This dissertation explores the use of BI tools for analyzing consumer behavior. A BI solution was developed based on a dataset of consumer shopping trends available on the Web. The main objective is to illustrate how data analysis can provide valuable insights for companies, enabling them to tailor their offerings, improve their marketing campaigns, and ultimately optimize their financial performance. In addition, a bibliometric analysis was performed using VOSviewer, allowing the identification of key scientific trends and contributions related to the application of BI in consumer behavior.

Key words: business intelligence; customer; segmentation; power bi

Índice geral

Capítulo I – Introdução.....	1
1.1 Contextualização e Motivação da Investigação.....	2
1.2 Questão de Investigação e Objetivos.....	2
1.3 Estrutura do Documento.....	3
Capítulo II – Revisão da literatura	5
2 Revisão Sistemática de Literatura- PRISMA	6
2.1 Descrição do Processo de Seleção de Estudos	7
2.1.1 Identificação	7
2.1.2 Triagem.....	8
2.1.3 Elegibilidade.....	8
2.1.4 Inclusão.....	8
2.2 Critérios de Inclusão e Exclusão	8
2.3 Fluxograma- Modelo PRISMA	9
3 Introdução.....	9
3.1 Importância do estudo do comportamento do consumidor	9
3.2 O Papel do Business Intelligence (BI) na Tomada de Decisão	10
4 Comportamento do Consumidor e Tomada de Decisão.....	11
4.1 Definição e teorias sobre o comportamento do consumidor	11
4.2 Evolução da tomada de decisão do consumidor no ambiente digital	13
4.3 Dados e <i>insights</i> , o motor da personalização e experiência do consumidor	14
5 Business Intelligence (BI) e Análise do Comportamento do Consumidor.....	16
5.1 Definição e evolução do BI	16
5.2 Os principais pilares do ciclo de vida do BI.....	17
5.2.1 <i>Data Warehousing</i>	18
5.2.2 <i>Extract, Transform, Load (ETL)</i>	18
5.2.3 <i>Analytics</i>	19

5.2.4	Visualização de Dados.....	19
5.3	BI no contexto empresarial.....	20
5.3.1	<i>Power BI</i>	20
5.4	Como o BI transforma dados em <i>insights</i> acionáveis.....	21
5.4.1	Integração dos dados	21
5.4.2	Transformação dos dados (ETL).....	21
5.4.3	Análise dos dados	22
5.4.4	Visualização dos dados.....	22
5.4.5	Geração de Conhecimento e <i>Insights</i>	22
5.4.6	Suporte à Tomada de Decisão	23
5.5	Aplicações do BI na análise do comportamento do consumidor.....	23
Capítulo III – Metodologia		25
6	CRISP-DM	26
6.1	Compreensão do Negócio (<i>Business Understanding</i>).....	26
6.2	Entendimento dos Dados (<i>Data Understanding</i>)	27
6.3	Preparação dos Dados (<i>Data Preparation</i>)	29
6.4	Modelação de Dados (<i>Modeling</i>)	30
6.5	Avaliação (<i>Evaluation</i>).....	34
6.6	Implementação (<i>Deployment</i>).....	35
Capítulo IV – Análise de resultados.....		36
7	<i>Dashboards</i>	37
7.1	<i>Dashboard 1</i> — Visão Geral e Segmentação Demográfica.....	38
7.2	<i>Dashboard 2</i> — Métodos de Pagamento, Envio e Sazonalidade.....	40
7.3	<i>Dashboard 3</i> — Identificação de Variáveis Influenciadoras	41
7.4	<i>Dashboard 4</i> — Árvore de Decomposição da Receita.....	43
7.5	<i>Dashboard 5</i> — PromoCode & Perfil do Cliente.....	44
7.6	<i>Dashboard 6</i> — Localização e Cruzamentos.....	46

7.7	Relação entre os <i>Dashboards</i> e as Questões de Investigação	48
7.7.1	Quais são os perfis mais comuns de consumidores?	48
7.7.2	Que categorias de produto têm maior adesão por género, faixa etária ou método de pagamento?	49
7.7.3	Existem padrões temporais ou regionais no consumo?	49
8	Análise Bibliométrica das Tendências de Compra.....	50
8.1	Metodologia da Análise Bibliométrica- VOSviewer e Web of Science.....	50
8.1.1	Critérios de Pesquisa	51
8.1.2	Exportação e Análise dos Dados	51
8.2	<i>Clusters</i> de Tendências Identificados.....	51
8.2.1	Género e Comportamento de Consumo.....	52
8.2.2	Método de Pagamento e Faixa Etária.....	53
8.2.3	Preferências no Método de Envio.....	54
8.2.4	Sazonalidade e Comportamento de Compra	55
8.2.5	Categorias de Produtos e Decisões de Compra	56
8.2.6	Localização no Consumo.....	57
8.3	Comparação com os Resultados do <i>Power BI</i>	57
	Capítulo V – Conclusão.....	60
8.4	Limitações	61
8.5	Propostas para Trabalhos Futuros.....	62
	Referências bibliográficas.....	63

Índice de Figuras

Figura 1- Modelo de fluxograma PRISMA 2020 para revisões sistemáticas (Adaptado de Page et al., 2021)	9
Figura 2- Modelo de BI segundo Watson & Wixom (2007).....	18
Figura 3- Metodologia CRISP-DM (Adaptado de Martinez-Plumed et al., (2021)).....	27
Figura 4- Modelo Relacional em Estrela (Star Schema)	31
Figura 5- Tabela de Factos (FactTransactions)	33
Figura 6- Tabela Measures- medidas DAX.....	34
Figura 7- Dashboard 1 — Visão Geral e Segmentação Demográfica.....	38
Figura 8- Dashboard 2 — Métodos de Pagamento, Envio e Sazonalidade.....	40
Figura 9- Dashboard 3 — Identificação de Variáveis Influenciadoras	42
Figura 10- Dashboard 4 — Árvore de Decomposição da Receita	43
Figura 11- Dashboard 5 — PromoCode & Perfil do Cliente	45
Figura 12- Dashboard 6 — Localização e Cruzamentos.....	47
Figura 13- Termos de Pesquisa- Web of Science.....	51
Figura 14- Mapa de coocorrência de termos relacionados com o género e comportamento de consumo.....	52
Figura 15- Mapa de coocorrência de termos relacionados com métodos de pagamento e faixa etária	53
Figura 16- Mapa de coocorrência de termos relacionados com a preferência nos métodos de envio.....	54
Figura 17- Mapa de coocorrência de termos relacionados com a sazonalidade e o comportamento do consumidor	55
Figura 18- Mapa de coocorrência de termos relacionados com as categorias de produtos e decisões de compra	56
Figura 19- Mapa de coocorrência de termos relacionados com o impacto da localização no consumo.....	57

Índice de Tabelas

Tabela 1- Critério de Inclusão e Exclusão para pesquisa de artigos- Web of Science.....	8
Tabela 2- Descrição do Conjunto de Dados	28

Lista de abreviaturas

BI- *Business Intelligence*

BDA- *Big Data Analytics*

KPIs- *Key Performance Indicators*

PRISMA- *Preferred Reporting Items for Systematic reviews and Meta-Analyses*

DAX- *Data Analysis and Expressions*

ETL- *Extract, Transform, Load*

CRISP-DM- *Cross Industry Standard Process for Data Mining*

CAPÍTULO I – INTRODUÇÃO

1.1 Contextualização e Motivação da Investigação

Atualmente, as empresas têm acesso a uma enorme quantidade de dados provenientes de diversas fontes, como interações com clientes, redes sociais, histórico de compras e comportamento online, o que tem vindo a transformar a forma como compreendem e se relacionam com os consumidores. Esta realidade, destacada por Gurcan et al. (2023), reflete uma mudança significativa na abordagem empresarial, que passa a ser mais orientada por evidências do que por intuição.

O interesse em estudar o papel do *Business Intelligence* (BI) na análise do comportamento do consumidor emerge da necessidade de perceber como as empresas transformam dados em decisões e reforçam a relação com os seus clientes.

Segundo Chen et al. (2012), a diversidade de dados permite às organizações obter uma visão mais detalhada das preferências e necessidades dos seus clientes. Pancić et al. (2023) reforçam que, ao ultrapassar os limites das metodologias tradicionais, as empresas conseguem adaptar-se melhor às exigências do mercado.

A análise integrada de dados, como referem Sukopová et al., (2023), contribui para uma compreensão mais completa do comportamento do consumidor. Com o apoio de ferramentas de BI, é possível identificar padrões de compra, preferências de produtos e canais de comunicação mais eficazes (Niu et al., 2021).

Neste contexto, o BI desempenha um papel estratégico, ao possibilitar que as empresas explorem tendências e planeiem ações mais direcionadas, como sublinhado por Prevedello et al. (2008).

Neste sentido, a relevância deste trabalho de investigação reside na necessidade crescente das empresas de transformar grandes volumes de dados em informações úteis para apoiar decisões estratégicas no estudo do comportamento do consumidor. O uso de ferramentas como o *Power BI* democratiza o acesso a análises avançadas, proporcionando visualizações claras, relatórios e *dashboards* intuitivos que auxiliam as empresas a caracterizar melhor os seus consumidores.

1.2 Questão de Investigação e Objetivos

A investigação desenvolvida neste estudo procura responder à seguinte pergunta: “De que forma o *BI* pode apoiar a caracterização do perfil do consumidor?”.

No sentido de responder a esta questão, foram elaborados os seguintes objetivos específicos:

- Identificar um conjunto de métricas e indicadores (KPIs- *Key Performance Indicators*) que permitam caracterizar o consumidor, como padrões de consumo, género, faixa etária, sazonalidade, valores gastos e métodos de pagamento;
- Desenvolver uma solução orientada à exploração e tratamento de dados, recorrendo à construção de um modelo dimensional no *Power BI*, estruturado segundo princípios de modelação em estrela;
- Elaboração de painéis interativos e representações visuais (*dashboards*) que facilitem a análise da informação armazenada no modelo dimensional, permitindo o seu acompanhamento contínuo e contribuindo para decisões mais informadas no âmbito da compreensão do comportamento do consumidor.

1.3 Estrutura do Documento

Este trabalho está dividido em cinco partes principais, cada uma dedicada a uma etapa específica da investigação:

- I- Introdução: No capítulo I é descrito o modelo de investigação, que detalha os objetivos, as principais variáveis analisadas e o enquadramento conceptual da dissertação.
- II- Contextualização Teórica: O capítulo II inclui uma revisão da literatura sobre o comportamento do consumidor e o papel do BI na tomada de decisão.
- III- Metodologia: O terceiro capítulo aborda a metodologia utilizada, explicando os métodos de recolha e análise de dados.
- IV- Análise de Resultados: Neste capítulo são apresentados os resultados da análise exploratória e das segmentações realizadas, com a discussão das conclusões mais significativas.
- V- Conclusão: Por fim, o capítulo V conclui a dissertação, sintetizando as principais contribuições da investigação, destacando as suas limitações e propondo direções para estudos futuros.

Ao longo deste trabalho, pretende-se exemplificar como o uso de BI pode apoiar o estudo do comportamento do consumidor, num ambiente de negócios cada vez mais competitivo e orientado por dados. Para enriquecer a investigação teórica, foi também realizada uma

análise bibliométrica com recurso ao *VOSviewer*, permitindo identificar tendências científicas relevantes na aplicação do BI ao comportamento do consumidor.

CAPÍTULO II – REVISÃO DA LITERATURA

Para conduzir esta revisão de literatura, foi utilizada a abordagem sistemática, orientada pelas diretrizes do *Preferred Reporting Items for Systematic reviews and Meta-Analyses* (PRISMA), conforme descrito por Page, McKenzie, et al. (2021). Esta metodologia permite uma análise crítica da evidência empírica disponível, assegurando que os estudos incluídos sejam identificados, selecionados, avaliados e sintetizados de forma estruturada e transparente (Page, Moher, et al., 2021). O PRISMA 2020 foi utilizado como referência para assegurar a clareza e a completude do relato desta revisão, permitindo que os métodos empregados e os resultados obtidos sejam compreendidos e avaliados de forma adequada.

A revisão de literatura deste estudo estabelece os conceitos-chave que sustentam a análise do comportamento do consumidor e a aplicação de tecnologias de BI como suporte estratégico, no sentido de perceber como o BI pode melhorar o estudo do consumidor. Nesta seção, primeiramente, analisa-se o comportamento do consumidor, destacando os fatores que influenciam as suas decisões de compra e as interações com produtos, serviços e marcas. Avançando para a dimensão tecnológica, introduz-se o BI como um suporte vital para transformar dados brutos em *insights* acionáveis, permitindo às empresas compreender melhor os consumidores e melhorar a eficiência das suas decisões. Destaca-se o papel do *Power BI* enquanto ferramenta de BI, com ênfase nas suas funcionalidades para visualização, integração e análise de dados. E por fim, é aprofundado o tópico da aplicação do BI na análise do comportamento do consumidor através de um caso de estudo.

Esta estrutura permite explorar os conceitos de forma sequencial e integrada, oferecendo uma base sólida para o desenvolvimento da investigação e para a aplicação prática dos resultados.

2 Revisão Sistemática de Literatura- PRISMA

A revisão sistemática de literatura, segundo Liberati et al. (2009), tem como objetivo reunir estudos que cumpram critérios previamente definidos, de forma a responder com rigor a uma pergunta de investigação específica. Este tipo de abordagem recorre a métodos estruturados e transparentes, que ajudam a reduzir possíveis enviesamentos e a garantir resultados fiáveis, úteis para sustentar decisões informadas. Para isso, é essencial definir objetivos claros e seguir uma metodologia explícita e reproduzível. A pesquisa

deve ser conduzida de forma sistemática, garantindo a identificação de todos os estudos relevantes que atendam aos critérios de elegibilidade.

A diretriz PRISMA foi criada com o objetivo de melhorar a transparência e qualidade dos relatórios de revisões sistemáticas e meta-análises, evoluindo a partir do QUOROM (Quality Of Reporting Of Meta-analysis), publicada em 1999 (Liberati et al., 2009). Desenvolvida por especialistas internacionais, esta ferramenta inclui uma checklist com 27 itens e um diagrama de fluxo dividido em quatro etapas, que orientam o processo de revisão de forma estruturada e clara.

Em 2020, a diretriz foi atualizada para PRISMA 2020, incorporando melhorias que refletem avanços metodológicos na identificação, seleção, avaliação e síntese dos estudos (Page et al., 2021). O seu uso contribui para relatórios mais completos e precisos, permitindo que os autores comuniquem com maior clareza os objetivos, métodos e resultados das suas revisões.

2.1 Descrição do Processo de Seleção de Estudos

A seleção dos estudos foi realizada com base neste protocolo de revisão sistemática de literatura, garantindo transparência e reprodutibilidade. O processo foi dividido nas seguintes etapas:

2.1.1 Identificação

A pesquisa de artigos foi realizada na base de dados Web of Science, utilizando a seguinte expressão booleana:

("consumer behavior" OR "consumer decision-making") AND

("business intelligence" OR "data analytics" OR "big data") AND

("decision-making" OR "marketing analytics").

Foram aplicados os seguintes critérios de inclusão e exclusão (filtros) para refinar os resultados:

- Acesso aberto (*open access*)
- Ano de publicação: 2021-2025
- Idioma: Inglês e Português
- Tipo de documento: Artigos e Revisões

- Área de conhecimento: *Business, Management, Marketing e Computer Science*

A pesquisa inicial resultou em 46042 artigos. Após a aplicação dos filtros, o número foi reduzido para 10884.

2.1.2 Triagem

Apesar da aplicação dos filtros iniciais, o número de artigos ainda era elevado. Para garantir maior relevância dos estudos selecionados, a estratégia de pesquisa foi refinada, restringindo os termos para aparecerem apenas nos títulos dos artigos, em vez de em qualquer parte do texto. Essa modificação permitiu reduzir os resultados a publicações cujo foco principal está diretamente relacionado ao tema da pesquisa, tornando a triagem mais eficiente e precisa. Com esta restrição, o número de artigos reduziu para 470.

2.1.3 Elegibilidade

Para tornar a seleção ainda mais precisa, foi removido o termo “*big data*”, que, pela sua amplitude, poderia incluir artigos menos alinhados ao foco da pesquisa. Esta nova filtragem reduziu os resultados para 150 artigos.

2.1.4 Inclusão

Em seguida, foi realizada a leitura dos títulos e resumos, resultando na seleção final de 26 artigos para posteriormente realizar uma análise detalhada.

2.2 Critérios de Inclusão e Exclusão

Critério	Descrição
Inclusão	Estudos que abordam comportamento do consumidor e BI
	Publicados entre 2021 e 2025
	Disponíveis em acesso aberto
	Escritos em inglês ou português
	Artigos revisados por pares (empíricos ou revisões sistemáticas)
Exclusão	Estudos focados apenas em aspectos de sistemas de BI
	Artigos de opinião, teses, dissertações, relatórios
	Estudos em idiomas diferentes de inglês ou português
	Artigos que não estão disponíveis para leitura completa

Tabela 1- Critério de Inclusão e Exclusão para pesquisa de artigos- Web of Science

2.3 Fluxograma- Modelo PRISMA

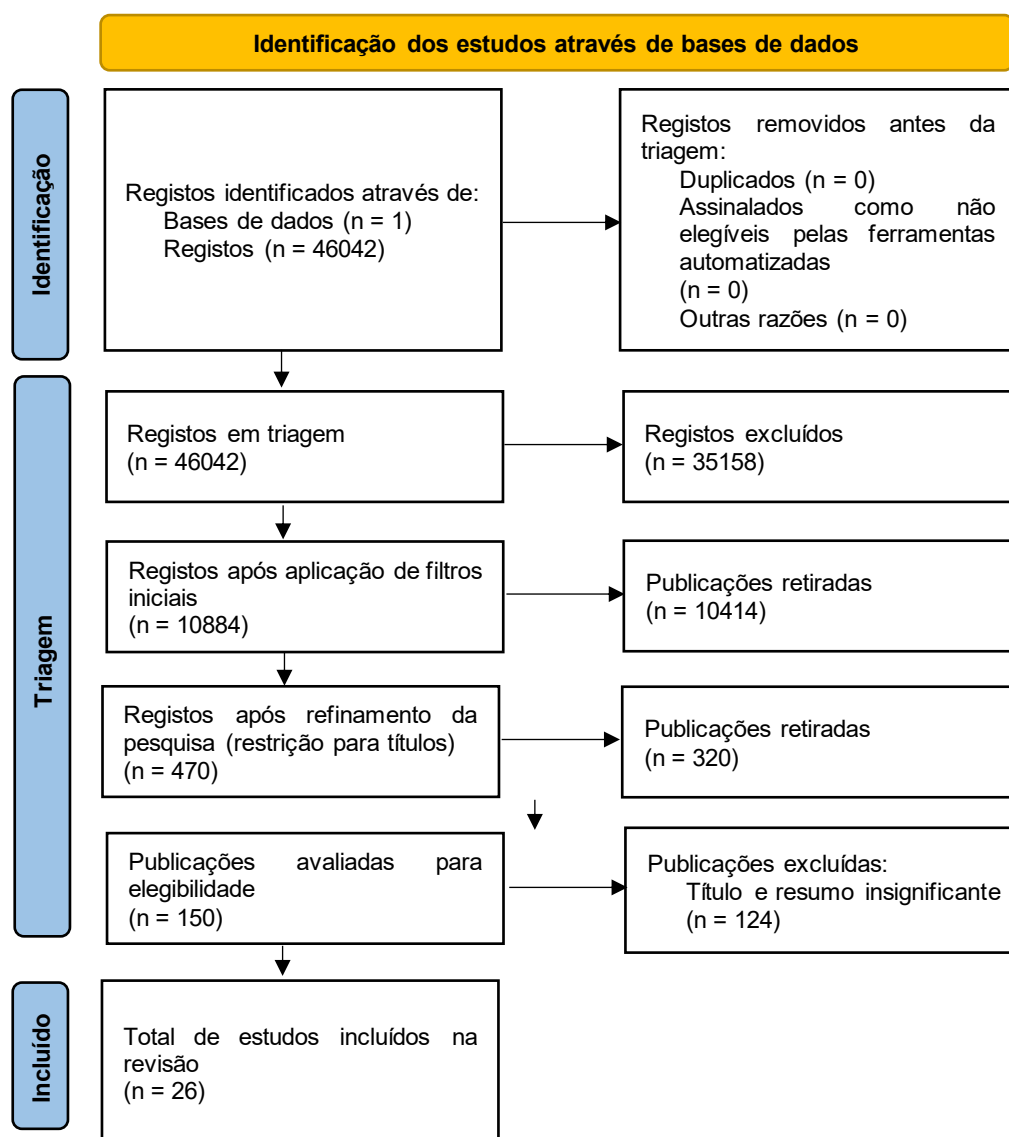


Figura 1- Modelo de fluxograma PRISMA 2020 para revisões sistemáticas (Adaptado de Page et al., 2021)

3 Introdução

3.1 Importância do estudo do comportamento do consumidor

As transformações digitais das últimas décadas têm alterado a forma como as empresas observam e interpretam o comportamento do consumidor (Włodarczyk, 2021). A capacidade de interpretar preferências e decisões de compra é fundamental para que as organizações se mantenham competitivas num mercado em constante evolução (Shwawreh & Awamleh, 2025).

Como referem Alawadh & Barnawi, (2024), é crucial que as empresas ajustem continuamente as suas estratégias, respondendo de forma proativa às novas exigências dos consumidores. A análise comportamental, neste contexto, permite identificar os elementos que influenciam a escolha de produtos, a fidelização e a satisfação dos clientes.

O uso de métodos analíticos baseados em dados permite às organizações antecipar tendências, segmentar públicos com maior precisão e reforçar a sua posição competitiva no mercado (Alawadh & Barnawi, 2024).

A crescente digitalização e o uso massivo de dados proporcionaram novas formas de entender o consumidor. Plataformas como o comércio eletrónico, as redes sociais e o marketing digital geram diariamente grandes volumes de dados diversificados, cuja análise pode revelar padrões de comportamento e preferências (Włodarczyk, 2021).

O BI destaca-se como uma ferramenta essencial nesse contexto, ao transformar dados dispersos em conhecimento estratégico que sustenta decisões mais eficazes e experiências de consumo mais personalizadas (Picozzi et al., 2024). Compreender o comportamento do consumidor tornou-se, assim, um fator-chave para a inovação e resiliência das empresas perante mudanças económicas e sociais (Włodarczyk, 2021).

Alawadh & Barnawi (2024) destacam que a capacidade de antecipar tendências e ajustar estratégias às novas expectativas dos consumidores representa uma vantagem competitiva significativa. Num cenário cada vez mais orientado por dados, a análise comportamental não só sustenta decisões estratégicas, como também impulsiona a criação de valor para clientes e organizações (Picozzi et al., 2024).

3.2 O Papel do Business Intelligence (BI) na Tomada de Decisão

Atualmente, o BI tem um papel fundamental nas empresas, pois transforma dados em *insights* acionáveis que apoiam a tomada de decisões em vários níveis (Mositsa et al., 2023). A análise de grandes volumes de informação permite uma leitura mais profunda do mercado, dos clientes e do desempenho interno, promovendo decisões mais informadas (Awan et al., 2021).

O impacto do BI pode ser observado em várias dimensões:

- **Precisão nas decisões:** Ao basear-se em dados concretos e análises rigorosas, o BI substitui decisões intuitivas por abordagens fundamentadas, reduzindo incertezas e riscos (Picozzi et al., 2024; Basu et al., 2023).
- **Apoio estratégico:** Os sistemas de BI oferecem uma visão integrada do negócio, facilitando a definição de estratégias, a identificação de oportunidades e a simulação de cenários futuros (Mositsa et al., 2023; Kongthanasuwan et al. (2023).
- **Eficiência operacional:** Através de dashboards e relatórios interativos, os gestores podem acompanhar indicadores em tempo real, otimizar recursos e agir rapidamente (Shwawreh & Awamleh, 2025).
- **Compreensão do consumidor:** O BI permite analisar preferências, hábitos e motivações dos clientes, o que facilita a segmentação e a personalização de campanhas (Basu et al., 2023; Mositsa et al., (2023)
- **Monitorização de desempenho:** As ferramentas de BI ajudam a acompanhar o progresso face aos objetivos definidos, sinalizando áreas críticas e avaliando o impacto das decisões (Picozzi et al., 2024).
- **Cultura orientada por dados:** A adoção do BI promove uma mentalidade analítica nas organizações, onde as decisões são sustentadas por evidência e não por suposições (Castillo & Del Río, 2023).

Em síntese, o BI atua como uma ponte entre a abundância de dados disponíveis e a necessidade de decisões assertivas em todos os níveis da organização. As suas funcionalidades não só permitem compreender o presente e o passado, como também antecipar cenários futuros, reforçando a competitividade e a sustentabilidade empresarial (Mositsa et al., 2023; Shwawreh & Awamleh, 2025).

4 Comportamento do Consumidor e Tomada de Decisão

4.1 Definição e teorias sobre o comportamento do consumidor

O comportamento do consumidor abrange um conjunto de ações relacionadas com a procura, utilização e rejeição de produtos ou serviços, incluindo os processos de decisão que antecedem essas ações. Segundo Wlodarczyk, (2021), este fenómeno é influenciado

por fatores psicológicos, sociais e culturais, sendo fundamental para compreender como o ser humano toma decisões de compra num mercado cada vez mais dinâmico.

Inicialmente, este comportamento era interpretado sob uma perspectiva econômica, assumindo que os consumidores agiam de forma racional para maximizar os benefícios dos bens adquiridos (Włodarczyk, 2021). No entanto, essa visão tem sido questionada por diversas abordagens da economia comportamental, como a Teoria do Comportamento Planeado, a Teoria do Comportamento Impulsivo, a Teoria Interpessoal do Comportamento, a *Alphabet Theory* e a Teoria do Enquadramento de Objetivos, presentes no artigo de Taghikhah et al. (2021). Estas perspectivas mostram que a tomada de decisão é complexa e multifacetada, influenciada por emoções, hábitos, normas sociais e objetivos pessoais.

Um dos fenômenos mais estudados é o chamado "hiato intenção-comportamento" (*intention-behavior gap*), que descreve a discrepância entre o que os consumidores pretendem fazer e o que efetivamente fazem, especialmente em contextos de consumo sustentável (Taghikhah et al., 2021). Liashenko et al. (2021) acrescentam que, para lidar com essa complexidade, as pessoas usam heurísticas, como a disponibilidade, a similaridade e as âncoras, que atuam como atalhos mentais, mas podem causar vieses cognitivos.

Em relação aos estilos de tomada de decisão, os consumidores adotam diversas estratégias, como priorizar a qualidade, ser fiel à marca, seguir tendências, agir de forma impulsiva e ser sensível ao preço (Abdel Wahab et al., 2023). O grau de envolvimento com o produto também é importante, pois define o tempo e a dedicação gastos na pesquisa antes da compra.

Teorias como a Identidade Social e a Categorização Social indicam que os consumidores formam parte do seu autoconceito com base nos grupos aos quais pertencem, o que influencia diretamente as suas escolhas e preferências (White et al., 2024). Por outro lado, a Teoria das Fundações Morais sugere que valores como justiça, lealdade e autoridade influenciam a percepção dos consumidores em relação a marcas e produtos, impactando até mesmo a maneira como respondem ao ativismo corporativo (Goenka & Thomas, 2024).

Além disso, a consciência coletiva tem um papel importante, uma vez que a sensação de pertença a um grupo pode influenciar as escolhas individuais (White et al., 2024). Por sua

vez, o Modelo de Perspetiva Comportamental vê o comportamento do consumidor como um processo contextual, influenciado pelas experiências anteriores e pelas consequências das ações, sejam elas utilitárias ou sociais (Gordon R et al., 2021).

Perante esta diversidade de abordagens, torna-se evidente que o comportamento do consumidor é um campo de estudo multidisciplinar, combinando perspetivas económicas, psicológicas e sociais. Compreender esses fatores é essencial para empresas e organizações que desejam otimizar as suas estratégias de marketing e gestão. Além disso, com o avanço das tecnologias e das ferramentas de BI, as organizações podem analisar padrões de comportamento e transformar esses *insights* em decisões estratégicas e operacionais mais eficazes.

4.2 Evolução da tomada de decisão do consumidor no ambiente digital

A evolução da tomada de decisão do consumidor no ambiente digital tem sido impulsionada pelo avanço da tecnologia da informação e pela crescente conectividade proporcionada pela internet. No início, os modelos de comportamento do consumidor não previam as especificidades do meio digital. Com o avanço da tecnologia, esse cenário mudou rapidamente. Uma das transformações mais significativas foi o acesso sem precedentes à informação, o que possibilitou aos consumidores pesquisar, comparar produtos e serviços, ler avaliações de outros utilizadores e obter detalhes sobre marcas de forma rápida e conveniente (Chatterjee et al., 2023). Esse contexto alterou a relação de poder entre consumidores e empresas, fazendo com que os consumidores se tornassem mais informados e criteriosos nas suas decisões (Cadden et al., 2023).

Com a expansão do negócio eletrónico, o processo de tomada de decisão começou a ocorrer num ambiente digital, no qual o consumidor atua em simultâneo como comprador e como utilizador das plataformas tecnológicas (Guo & Zhai, 2022). A perceção de utilidade e a facilidade de navegação passaram a ser fatores essenciais na formação das atitudes e intenções de compra, afetando diretamente o desempenho das lojas online (Guo & Zhai, 2022). Simultaneamente, o *marketing* digital avançou rapidamente, incorporando técnicas *marketing* de precisão baseadas em análise de dados. Isso possibilitou que as empresas entendessem de forma mais aprofundada os padrões de comportamento dos consumidores online (Basu et al., 2023). A recolha e o processamento de grandes volumes de dados sobre o comportamento dos utilizadores têm possibilitado aplicar estratégias de

segmentação e recomendação mais precisas, melhorando a experiência de compra e aumentando a eficácia das campanhas promocionais (Guo & Zhai, 2022).

A introdução da Inteligência Artificial, particularmente através de métodos como a aprendizagem automática e os algoritmos de aprendizagem profunda (*Deep Learning*), revolucionou ainda mais a maneira como se estuda o comportamento do consumidor no ambiente digital (Xu et al., 2024). Estes modelos avançados permitem identificar padrões complexos e antecipar comportamentos futuros, proporcionando recomendações mais exatas e campanhas de *marketing* altamente personalizadas (Zhang et al., 2023). Além disso, a decisão de compra no meio digital é fortemente influenciada por fatores sociais e comunitários. As redes sociais, as avaliações de outros utilizadores e as comunidades em torno das marcas desempenham um papel relevante, pois a opinião de outros consumidores pode ter um impacto significativo nas decisões pessoais (Shwawreh & Awamleh, 2025). A confiança tanto nas plataformas quanto nos vendedores tornou-se também determinante, sendo muitas vezes estabelecida por meio de sistemas de reputação e *feedback* (Guo & Zhai, 2022).

Atualmente, nota-se um aumento na implementação de estratégias omnicanal, nas quais os clientes comunicam com as marcas por meio de diversos canais, combinando experiências online e offline de forma integrada e sem dificuldades (Dehnert & Schumann, 2022). Esse comportamento reflete uma mudança na jornada de compra, onde os indivíduos utilizam diferentes canais em momentos distintos do processo de decisão. Ao olhar para o futuro, é provável que tecnologias emergentes, como assistentes virtuais baseados em IA e experiências imersivas no metaverso, comecem a ter um papel ainda mais importante (Basu et al., 2023). Estas inovações poderão transformar a interação entre consumidores e marcas, criando formas de experimentação de produtos e serviços e alterando significativamente a dinâmica da tomada de decisão no ambiente digital.

4.3 Dados e *insights*, o motor da personalização e experiência do consumidor

No contexto digital atual, os dados assumem um papel crucial na criação de experiências mais significativas para os consumidores. Por meio da análise de dados, as empresas podem entender melhor os seus clientes e criar interações mais eficientes (Awan et al., 2021).

A recolha e análise de grandes volumes de dados possibilitam a identificação de padrões de compra, preferências e comportamentos, permitindo a personalização de ofertas e

experiências (Guo & Zhai, 2022). Esta capacidade de adaptação é particularmente importante num mercado em que o interesse e a procura dos consumidores muda rapidamente.

A utilização de ferramentas como o *Big Data Analytics* (BDA), o BI ou o *Marketing Analytics*, tem sido essencial para transformar dados em ações reais dentro das empresas (Agag et al., 2024). Além de entender o consumidor, estas tecnologias ajudam a prever tendências e necessidades, melhorando a comunicação e o relacionamento com o público (Gordon R et al., 2021).

A personalização tornou-se, assim, uma estratégia fundamental para as empresas que procuram destacar-se num mercado competitivo (Basu et al., 2023). Com o apoio de algoritmos de *deep learning* e análise de sequências de compra, é possível recomendar produtos e serviços relevantes, bem como, ajustar preços, promoções e canais de comunicação (Xu et al., 2024).

Para além da personalização da oferta, os dados também desempenham um papel importante na adaptação da experiência do utilizador em diferentes pontos de contacto (Cadden et al., 2023). A análise do comportamento em *websites*, aplicações móveis e redes sociais permite melhorar a funcionalidade das plataformas, tornando a navegação mais intuitiva e aumentando a satisfação do consumidor (Kongthanasuwan et al., 2023). Esta capacidade de responder rapidamente às mudanças nas preferências dos clientes contribui para uma proposta de valor mais sólida e ajustada (Basu et al., 2023).

Um exemplo claro da aplicação prática da análise de dados é o *marketing* de precisão, que assegura que a mensagem adequada chega ao consumidor certo, no momento certo e pelo canal mais eficaz (Guo & Zhai, 2022). Ao entender os comportamentos dos consumidores, tanto *online* como *offline*, as marcas conseguem direcionar campanhas com maior eficiência, reduzindo desperdícios e aumentando o retorno sobre o investimento (Corboş et al., 2023). Essa abordagem não só melhora os resultados das campanhas, como também reforça a consistência e o envolvimento com a marca (Guo & Zhai, 2022).

Por último, a personalização e a adaptação da experiência do consumidor, motivadas pela análise de dados, exercem uma influência direta na satisfação e na lealdade dos consumidores (Castillo & Del Río, 2023). Quando os clientes percebem que uma marca entende as suas necessidades e oferece soluções pertinentes, é mais provável que criem

uma ligação emocional e regressem em futuras compras (Agag et al., 2024). Desta forma, as empresas que usam dados de forma estratégica para oferecer experiências personalizadas não só melhoram a sua relação com os clientes, como também ganham uma vantagem competitiva no mercado.

Em suma, os dados e os *insights* que deles derivam são a base para a personalização e a experiência do consumidor no ambiente digital. As empresas que dominam a arte de transformar informação em valor agregado para os clientes encontram-se numa posição privilegiada para construir relacionamentos duradouros, melhorar a satisfação do consumidor e, conseqüentemente, reforçar a sua posição no mercado (Basu et al., 2023).

5 Business Intelligence (BI) e Análise do Comportamento do Consumidor

5.1 Definição e evolução do BI

A origem do conceito de BI remonta à publicação de Luhn (1958), no âmbito de uma proposta pioneira para um sistema automatizado de gestão da informação. Apesar de esta perspetiva ter surgido num contexto tecnológico ainda inicial, ela já demonstrava preocupação com a estruturação e a utilização estratégica dos dados.

Em 1989, H. Dresner (do Gartner Group), definiu o BI como um conjunto de conceitos e métodos destinados a apoiar a tomada de decisões numa empresa utilizando sistemas baseados em conhecimento (Dresner, 1989, conforme citado em Bańka et al., 2022). Ao admitir que a informação, quando bem estruturada, poderia ser convertida em vantagem competitiva, essa definição representou um ponto de viragem.

Mais recentemente, autores como Necochea-Chamorro & Larrea-Goycochea (2023) ampliaram essa visão, descrevendo o BI como um processo que engloba a análise e a apresentação de dados no âmbito organizacional, com o objetivo de apoiar decisões estratégicas. Awan et al. (2021) reforçam que o BI combina uma variedade de técnicas e tecnologias que ajudam as empresas a entender melhor os seus mercados, identificar padrões e antecipar oportunidades, diminuindo a incerteza e tornando o processo de tomada de decisão mais informado e oportuno.

Esta evolução do BI reflete uma mudança significativa na maneira como as empresas veem os dados: não apenas como registos operacionais, mas como ativos estratégicos. O aparecimento do conceito de *Business Intelligence and Analytics*, especialmente no

âmbito do *Big Data Analytics* (BDA), veio consolidar essa transformação. Nas duas últimas décadas, o BDA tornou-se essencial para empresas e instituições acadêmicas influenciando até mesmo áreas como a economia circular, onde tem auxiliado na tomada de decisões mais sustentáveis e fundamentadas (Awan et al., 2021).

Na prática, o avanço constante do BI tem dado possibilidade a que as empresas utilizem o BDA como recurso para ganhar vantagem competitiva, especialmente num mercado caracterizado pela instabilidade e pela necessidade constante de adaptação (Cadden et al., 2023). Segundo Kongthanasuwan et al. (2023), as ferramentas de BI tornaram-se fundamentais para otimizar processos, aumentar a eficiência operacional e fortalecer a precisão na gestão.

Inicialmente, os sistemas de BI eram projetados para apoiar decisões estratégicas de longo prazo, como análises baseadas em dados históricos e ciclos de decisão que duravam semanas ou meses (Mositsa et al., 2023). Nos dias de hoje, essa situação mudou radicalmente. A evolução de ferramentas como *Tableau*, *Power BI* e *Google Analytics* trouxe agilidade e capacidade de análise em tempo real, permitindo que decisões sejam tomadas com base em informações atualizadas e visualizações intuitivas. Esta mudança tem-se mostrado especialmente significativa em áreas como o *marketing* digital, onde a agilidade e a exatidão são fundamentais (Shwawreh & Awamleh, 2025).

Atualmente, o BI já não é apenas uma ferramenta de análise retrospectiva e passou a desempenhar também um papel preditivo e dinâmico. Impulsionado pelo progresso do *Big Data* e pela crescente exigência de decisões rápidas, o BI continua a transformar a maneira como as empresas usam os dados para aumentar a eficiência, otimizar operações e fortalecer o seu posicionamento estratégico (Necochea-Chamorro & Larrea-Goycochea, 2023).

5.2 Os principais pilares do ciclo de vida do BI

Segundo Watson & Wixom (2007), o BI é um processo que inclui duas grandes atividades primárias: entrada de dados (*getting data in*) e saída de dados (*getting data out*), sendo a primeira também chamada de *Data Warehousing*. A segunda é apelidada de BI e define-se como sendo um conjunto de aplicações que acedem aos dados do *Data Warehouse* para, posteriormente, executar análises descritivas, preditivas e prescritivas.

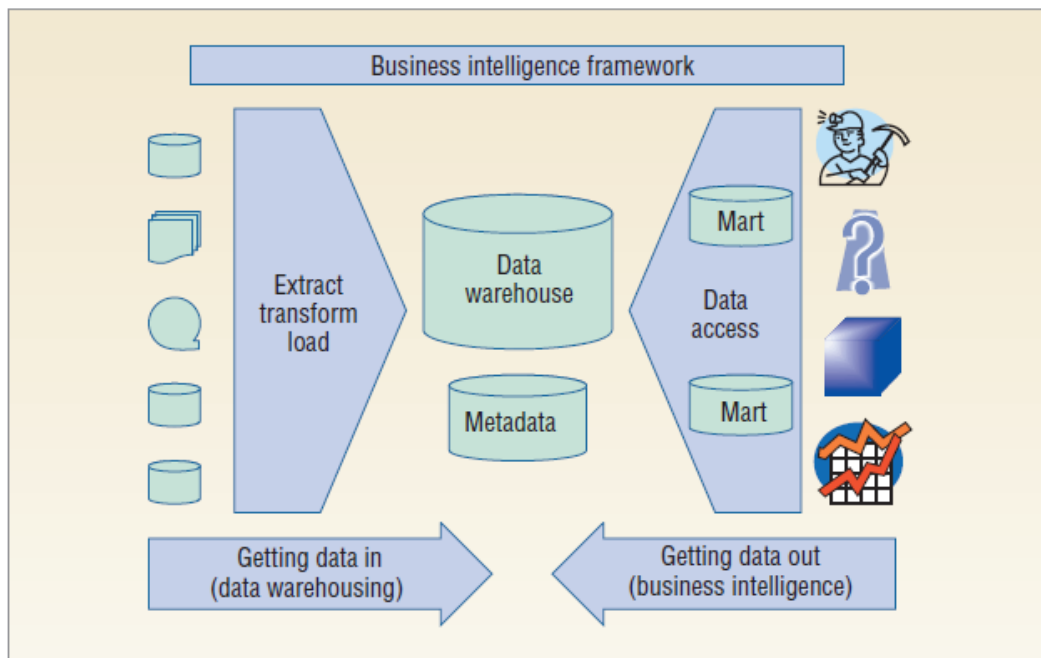


Figura 2- Modelo de BI segundo Watson & Wixom (2007)

5.2.1 Data Warehousing

A criação de um *Data Warehouse* é o primeiro passo fundamental do BI, normalmente conhecida como a fase de recolha e armazenamento de dados (Watson & Wixom, 2007).

De acordo com Mositsa et al. (2023) o *Data Warehouse* consiste num repositório centralizado onde os dados de diversas fontes são armazenados e organizados para análise. Contrariamente às bases de dados operacionais, e segundo o mesmo autor, um *Data Warehouse* mantém um registo histórico e não volátil da informação, permitindo a geração de *insights* estratégicos.

5.2.2 Extract, Transform, Load (ETL)

O processo de ETL (*Extract, Transform, Load* – Extração, Transformação e Carregamento) consiste num conjunto de tarefas fundamentais para a preparação dos dados operacionais para o ambiente de BI (Kimball & Ross, 2002).

O ETL é o processo que permite a extração de dados de diferentes fontes, a sua transformação em formatos padronizados e o armazenamento num *Data Warehouse* (Castillo & Del Río, 2023). Este procedimento é fundamental para assegurar a qualidade, integridade e acessibilidade das informações.

O processo de ETL é dividido em três etapas:

- Extração (E): Esta é a primeira etapa do processo de obtenção de dados no ambiente do *Data Warehouse* (Kimball & Ross, 2002). Estes sistemas de origem são tipicamente heterogêneos em termos de plataformas técnicas e estruturas de dados (Watson & Wixom, 2007).
- Transformação (T): Os dados extraídos são transformados para que sejam significativos para o suporte à decisão (Watson & Wixom, 2007).
- Carregamento (L): Os dados transformados são colocados num armazenamento de dados (*data store*), o qual é orientado por assunto, integrado, variante no tempo e não volátil (Watson & Wixom, 2007).

5.2.3 *Analytics*

O *Analytics* envolve a utilização de métodos avançados para identificar padrões, tendências e correlações que estão ocultas nos dados (Mositsa et al., 2023). Com o suporte de modelos de *Machine Learning* e IA, as empresas têm a possibilidade de otimizar operações, criar estratégias de *marketing* mais eficientes e melhorar a experiência do cliente (Proença & Martins, 2023). A análise de dados tornou-se um pilar fundamental na criação de conhecimento nas organizações, permitindo que as decisões sejam mais rápidas e informadas (Shwawreh & Awamleh, 2025).

5.2.4 **Visualização de Dados**

A apresentação visual de dados facilita a interpretação dos *insights* gerados, possibilitando que os responsáveis pela tomada de decisão entendam de forma rápida informações complexas (Mositsa et al., 2023). Neste processo, ferramentas como *Power BI*, *Tableau* e *Qlik Sense* têm-se destacado ao permitir criar *dashboards* personalizados e relatórios dinâmicos que tornam os dados mais compreensíveis e utilizáveis (Picozzi et al., 2024).

Conforme sustentado por Mositsa et al. (2023), o BI é um processo que abrange quatro etapas interconectadas e funcionais (*Data Warehousing*, ETL, *Analytics* e Visualização de Dados), que atuam em conjunto para transformar dados brutos em conhecimento valioso e oportuno, o qual impulsiona a tomada de decisões nas empresas.

5.3 BI no contexto empresarial

No contexto empresarial, diversas ferramentas são utilizadas para BI, e a escolha depende principalmente das necessidades específicas, preferências pessoais e características técnicas procuradas.

Com base nos artigos analisados, foram identificadas várias ferramentas utilizadas na análise de dados, entre as quais se destacam: *Power BI*, *Tableau*, *Google Analytics* (Shwawreh & Awamleh, 2025) *QlikView*, *Pentaho*, *Power Query* e *Power Pivot* (Necochea-Chamorro & Larrea-Goycochea, 2023).

Neste estudo, optou-se pela utilização do *Power BI*, devido à sua capacidade de realizar tarefas de preparação, modelação e visualização de dados num único ambiente. Embora não constitua uma plataforma completa de gestão do ciclo de vida dos dados, o *Power BI* permite efetuar operações de ETL ligeiro, modelar dados para análise e construir *dashboards* interativos que facilitam a extração de *insights* (Antal et al., 2022). Esta ferramenta permite às organizações ampliar o acesso à informação, promovendo uma cultura orientada por dados e tornando as decisões mais rápidas, ágeis e fundamentadas, o que se revela essencial num mercado cada vez mais competitivo (Kohara Melchior et al., 2023). Por essa razão, será sobre esta ferramenta de BI cuja revisão de literatura será aprofundada de seguida.

5.3.1 *Power BI*

De acordo com Kohara Melchior et al., (2023), o *Microsoft Power BI* é um serviço de BI lançado pela *Microsoft* em 2015, e, é uma das ferramentas mais aplicadas no setor empresarial (Necochea-Chamorro & Larrea-Goycochea, 2023).

O *Power BI* permite a conexão de diferentes fontes de dados (Sanabia-Lizarraga et al., 2024) e a integração dos mesmos, podendo estes ser provenientes de diversas fontes e formatos (Kohara Melchior et al., 2023). Esta é uma ferramenta desenvolvida para facilitar a visualização e a criação de relatórios interativos, permitindo uma análise eficiente, mesmo em casos de grandes volumes de dados (Sanabia-Lizarraga et al., 2024).

Uma das suas principais vantagens é a interface simples e intuitiva, que facilita a navegação até mesmo para utilizadores com pouca experiência (Kohara Melchior et al., 2023; C. T. Gonçalves et al., 2023). As atualizações frequentes e os gráficos pré-definidos ajudam a acelerar o processo de construção de relatórios e análises. Para além disso, o

Power BI permite criar medidas personalizadas e realizar várias manipulações através da linguagem DAX (*Data Analysis and Expressions*), cuja estrutura é semelhante à do *Excel*, o que facilita a aprendizagem de qualquer tipo de utilizador (Necochea-Chamorro & Larrea-Goycochea, 2023).

De acordo com Kohara Melchior et al. (2023), o *Power Bi* funciona como uma plataforma unificada e escalável, apropriada para ambientes empresariais e para análises pessoais. Dentro dos seus componentes mais importantes, estão o *Power Query*, que trata da extração, transformação e carregamento de dados (ETL), e o *Power Pivot*, responsável pela modelação de dados *in-memory*, permitindo cálculos, agregações e armazenamento eficiente de dados (Sousa et al., 2021).

No fundo, o *Power BI* oferece uma série de funcionalidades que possibilitam a integração de dados provenientes de diversas fontes, a análise aprofundada desses dados e a apresentação dos resultados através de relatórios, gráficos, visualizações e *dashboards* interativos (C. T. Gonçalves et al., 2023).

5.4 Como o BI transforma dados em *insights* acionáveis

O BI transforma dados brutos em *insights* acionáveis através de um processo multifacetado que envolve várias etapas (Antal et al., 2022).

5.4.1 Integração dos dados

As ferramentas de BI têm a capacidade de se conectar a diversas fontes de dados, mesmo quando estes apresentam formatos distintos (M. Gonçalves et al., 2025). Estas fontes podem ser bases de dados operacionais, folhas de cálculo, sistemas legados, plataformas *online*, redes sociais e até mesmo dados não estruturados (Brewis et al., 2023). Esta integração permite reunir a informação vinda de várias fontes num único local, facilitando a exploração dos dados e a geração de *insights* relevantes (Sousa et al., 2021).

5.4.2 Transformação dos dados (ETL)

A transformação dos dados é um dos procedimentos fundamentais no tratamento dos dados, conforme mencionado anteriormente no processo ETL (Picozzi et al., 2024). Após a extração dos dados, os mesmos devem ser transformados através de limpeza (remoção de erros e inconsistências), estruturação, filtragem, agregação e conversão para um formato consistente e adequado para análise (Baňka et al., 2022). E, finalmente, os dados

transformados são carregados num repositório centralizado, denominado de *Data Warehouse*, otimizado para consultas e análises (Kimball & Ross, 2002).

5.4.3 Análise dos dados

Com os dados integrados e transformados, as ferramentas de BI aplicam técnicas analíticas para descobrir padrões, tendências, correlações e *insights* significativos (Antal et al., 2022). Isto pode envolver:

- Análise descritiva: Compreender o que aconteceu no passado e o que está a acontecer no presente através da sumarização e visualização dos dados (Mositsa et al., 2023);
- Análise preditiva: Utilizar dados do passado e modelos estatísticos para prever o que poderá suceder-se no futuro (M. Gonçalves et al., 2025);
- Análise prescritiva: Prescrever o melhor a fazer com base nos *insights* obtidos (Awan et al., 2021);
- *Data Mining*: Investigar grandes volumes de dados para identificar padrões ocultos e relações não evidentes (Antal et al., 2022).

5.4.4 Visualização dos dados

Uma das qualidades do BI é a sua capacidade de apresentar visualmente os resultados da análise, tornando o seu entendimento fácil e apelativo (Sousa et al., 2021). Mesmo os utilizadores que não têm um conhecimento técnico aprofundado conseguem aceder a informação complexa, uma vez que esta é transformada por ferramentas de BI em *dashboards*, relatórios interativos, gráficos e tabelas (C. T. Gonçalves et al., 2023). O facto de a informação ser apresentada visualmente ajuda a que quem toma a decisão consiga identificar rapidamente tendências, anomalias e assuntos que requerem mais atenção (Bańka et al., 2022).

5.4.5 Geração de Conhecimento e *Insights*

Após estas etapas de integração, transformação, análise e visualização dos dados, segue-se a fase de tornar os dados brutos em informação útil e, subsequentemente, em conhecimento acionável (*insights*) (Picozzi et al., 2024). São estes *insights* que permitem ter uma compreensão mais aprofundada do negócio, e de tudo que o envolve como, os clientes, o mercado e as operações (M. Gonçalves et al., 2025).

5.4.6 Suporte à Tomada de Decisão

Por fim, são os *insights* gerados pelo BI que permitem que os gestores e decisores tomem decisões mais informadas, estratégicas e oportunas (C. T. Gonçalves et al., 2023). Uma empresa que tome decisões com base em dados concretos e análises rigorosas tem mais hipótese de alcançar os seus objetivos de negócio e, durante o processo, melhorar a sua eficiência e otimizar métodos, mas também identificar novas oportunidades e mitigar riscos (Kongthanasuwan et al., 2023). Para que haja um acompanhamento contínuo do desempenho da organização, os KPIs são essenciais, uma vez que permitem a adaptação e melhoria contínua do negócio (Baňka et al., 2022).

De uma forma simplificada, pode-se dizer que o BI serve de ligação entre os dados brutos e a ação estratégica, o que faz com que as organizações consigam extrair valor significativo da informação que têm (Basu et al., 2023). Esta informação, depois de passar pela integração, transformação, análise e visualização, é convertida em *insights* que podem ser diretamente aplicados para melhorar o desempenho de uma empresa e alcançar vantagens sobre outras organizações (Picozzi et al., 2024).

5.5 Aplicações do BI na análise do comportamento do consumidor

Na prática, o BI ajuda as empresas a conhecer melhor os seus clientes e a tomar decisões mais seguras e fundamentadas (Chatterjee et al., 2023). Ao analisar diferentes tipos de dados com apoio da IA e do *Machine Learning*, o BI permite descobrir padrões de consumo, preferências e tendências de mercado (Guo & Zhai, 2022). Assim, as empresas conseguem perceber o que os consumidores valorizam e ajustar as suas estratégias de forma mais eficaz.

De acordo com Chatterjee et al. (2023), o BI também pode ser usado para prever comportamentos futuros, analisando informações como o histórico de compras ou as interações dos clientes. Com técnicas de *Machine Learning*, os gestores conseguem antecipar mudanças e adaptar-se rapidamente às novas exigências do mercado (Liashenko et al., 2021).

O BI não se limita apenas aos dados quantitativos. Também permite analisar fatores emocionais e sociais que influenciam as decisões de compra, ajudando as empresas a responder melhor às necessidades dos clientes e a aumentar a sua satisfação (Agag et al., 2024).

Outra aplicação importante é a segmentação dos consumidores. Com o uso de técnicas como *clustering*, é possível agrupar clientes com comportamentos semelhantes. Além disso, os algoritmos de regras de associação ajudam a identificar ligações entre produtos e preferências de consumo (Alawadh & Barnawi, 2024). Estas análises são muito úteis para criar recomendações personalizadas, sobretudo em lojas online e campanhas de *marketing* (Zhang et al., 2023).

O BI também é utilizado na análise de sentimentos, que permite avaliar como os consumidores reagem às ações das empresas (Bańka et al., 2022). Aqui entram as ferramentas como o *Power BI* que facilitam esta tarefa através da criação de *dashboards* interativos que mostram os resultados de forma visual e simples (Sanabia-Lizarraga et al., 2024). No setor retalhista, *frameworks* baseados em *Machine Learning* ajudam a identificar padrões de compra e relações entre produtos e clientes, tornando as decisões comerciais mais informadas e eficazes (Alawadh & Barnawi, 2024).

Desta forma, a aplicação do BI na análise do comportamento do consumidor é fundamental para a criação de campanhas de *marketing* mais eficazes, previsão de tendências e melhoria na tomada de decisão. Ao integrar dados de diversas fontes e utilizar técnicas avançadas de análise, as empresas conseguem rapidamente adaptar-se às mudanças do mercado e oferecer experiências mais personalizadas aos seus clientes.

6 CRISP-DM

Para a análise do comportamento do consumidor, optou-se pela metodologia CRISP-DM (*Cross Industry Standard Process for Data Mining*), sendo esta muito utilizada em projetos de *data mining* (Schröer et al., 2021). Este modelo foi introduzido em 1999 (Martinez-Plumed et al., 2021), e a sua primeira versão foi lançada em 2000 (Schröer et al., 2021). Segundo os mesmos autores, esta metodologia é muito utilizada, tanto na indústria como no ensino, e continua a ser considerada ‘*de facto standard*’ em projetos de *data mining* (Bokrantz et al., 2023).

Embora o CRISP-DM tenha sido originalmente concebido para projetos de *data mining*, neste estudo a metodologia foi adaptada ao contexto de BI. Assim, apenas as fases compatíveis com uma análise exploratória foram aplicadas. As etapas de modelação e avaliação foram ajustadas à natureza ilustrativa da solução, e a fase de implementação não corresponde à implementação em ambiente organizacional real, mas sim ao desenvolvimento de *dashboards*.

A escolha desta metodologia revelou-se adequada ao tipo de análise pretendida, uma vez que permite estruturar o processo de investigação de forma lógica, iterativa e orientada a resultados (Schröer et al., 2021).

Segundo Elkabalawy et al. (2024), o método CRISP-DM consiste em seis etapas que, de seguida, serão descritas tendo em conta o presente estudo.

6.1 Compreensão do Negócio (*Business Understanding*)

A primeira fase do CRISP-DM assume a compreensão dos objetivos e necessidades do negócio (Bokrantz et al., 2023). No caso deste estudo, o objetivo principal é analisar o comportamento do consumidor com base em dados de compras, de forma a identificar padrões relevantes que possam sustentar decisões estratégicas com recurso a BI. Pretende-se responder a questões como:

- Quais são os perfis mais comuns de consumidores?
- Que categorias de produto têm maior adesão por género, faixa etária ou método de pagamento?
- Existem padrões temporais ou regionais no consumo?

6.2 Entendimento dos Dados (*Data Understanding*)

O objetivo desta fase é determinar precisamente que dados analisar, identificar a qualidade dos dados disponíveis e estabelecer a ligação entre os dados e o seu significado numa perspetiva de negócio (Lebkiri et al., 2021). As tarefas essenciais incluem a recolha de dados, a sua exploração e descrição, e a verificação da qualidade dos dados (Schröer et al., 2021).




Figura 3- Metodologia CRISP-DM (Adaptado de Martinez-Plumed et al., (2021))

O conjunto de dados utilizado foi obtido da plataforma *Kaggle*, sendo esta uma plataforma pertencente à Google que disponibiliza dados, para construir modelos, e participar em competições de *data science* (Adegoke, 2023). O conjunto de dados encontra-se disponível no endereço <https://www.kaggle.com/datasets/iamsouravbanerjee/customer-shopping-trends-dataset>, sob o título "*Customer Shopping Trends Dataset*". Este conjunto de dados contém informações sintéticas sobre o comportamento de compra de clientes, incluindo as seguintes variáveis e respetiva descrição:

Nome da Coluna	Descrição
<i>Customer ID</i>	Identificador único de cada cliente
<i>Age</i>	Idade do cliente
<i>Gender</i>	Género do cliente (Masculino/Feminino)
<i>Item Purchased</i>	Item adquirido pelo cliente
<i>Category</i>	Categoria do item adquirido
<i>Purchase Amount (USD)</i>	Valor da compra em dólares americanos
<i>Location</i>	Local onde a compra foi realizada
<i>Size</i>	Tamanho do item adquirido
<i>Color</i>	Cor do item adquirido
<i>Season</i>	Estação do ano em que a compra foi realizada
<i>Review Rating</i>	Avaliação dada pelo cliente ao item adquirido
<i>Subscription Status</i>	Indica se o cliente tem subscrição ativa (Sim/Não)
<i>Shipping Type</i>	Tipo de envio escolhido pelo cliente
<i>Discount Applied</i>	Indica se foi aplicado desconto na compra (Sim/Não)
<i>PromoCode Used</i>	Indica se foi usado código promocional na compra (Sim/Não)
<i>Previous Purchases</i>	Número de compras anteriores realizadas pelo cliente
<i>Payment Method</i>	Método de pagamento preferido pelo cliente
<i>Frequency of Purchases</i>	Frequência com que o cliente realiza compras (ex.: semanal, mensal, etc.)

Tabela 2- Descrição do Conjunto de Dados

Como o *dataset* usado é sintético, os resultados não representam consumidores reais. Por isso, a análise funciona sobretudo como uma prova de conceito, mostrando como o BI pode ser aplicado ao estudo do comportamento do consumidor. Os padrões encontrados são úteis para ilustrar o processo, mas só poderiam ser confirmados com dados reais de uma empresa.

Esta descrição ajudou a identificar o potencial analítico de cada variável e a orientar as decisões de limpeza, transformação e modelação dos dados nas fases seguintes do processo CRISP-DM.

Após a compreensão inicial do conjunto de dados, procedeu-se à fase de preparação dos dados, essencial para garantir a qualidade e a fiabilidade das análises subseqüentes. Esta etapa envolveu diversas operações fundamentais:

- Exploração inicial da estrutura: verificou-se que o conjunto de dados está organizado em formato tabular;
- Identificação de tipos de variáveis: foram distinguidas variáveis categóricas (ex.: tipo de envio, frequência de compra), numéricas (ex.: idade, valor da compra) e textuais (ex.: categoria de produto);
- Detecção de incoerências e redundâncias: observou-se a existência de categorias semânticas duplicadas, como por exemplo “*Quarterly*” e “*Every 3 Months*”, que representam a mesma frequência de compra, exigindo posterior normalização.
- Avaliação da qualidade dos dados: foram identificados valores nulos e duplicados, bem como colunas com pouca relevância analítica, o que orientou decisões na fase de preparação.
- Segmentação lógica das entidades: com base na natureza das variáveis, foi possível distinguir entre tabelas de dimensão (ex.: clientes, produtos, envio) e tabela de factos (transações), permitindo posteriormente a estruturação de um modelo relacional em estrela.

6.3 Preparação dos Dados (*Data Preparation*)

Nesta fase, os dados são preparados para a modelação, incluindo tarefas como seleção, limpeza e transformação dos dados (Bokrantz et al., 2023). Sendo que, de acordo com Schröer et al. (2021), a tarefa de transformação de dados é muitas vezes a mais complexa.

Esta etapa foi essencial para garantir a qualidade da análise a ser realizada no *Power BI*, tendo sido executadas as seguintes tarefas:

- Limpeza de dados: foram identificados e removidos registos com valores nulos e duplicados, de forma a assegurar a integridade e consistência da informação;
- Eliminação de atributos irrelevantes: foram excluídas variáveis que não apresentavam relevância para os objetivos da análise, nomeadamente atributos relacionados com características específicas dos produtos adquiridos (“*size*”, “*color*”), avaliações subjetivas (“*review rating*”) e indicadores promocionais ou comportamentais (“*discount applied*”, “*previous purchases*”). Esta decisão visou

simplificar o modelo, reduzir o ruído analítico e focar a investigação nos padrões de compra e perfil dos clientes.

- Transformações de variáveis: A coluna “*age*” foi transformada em grupos etários, permitindo uma segmentação mais eficaz dos clientes e facilitando a análise comportamental;
- Normalização de categorias: procedeu-se à uniformização de valores semântica e funcionalmente equivalentes, como por exemplo a consolidação dos termos “*Quarterly*” e “*Every 3 Months*” numa única categoria, bem como “*Bi-Weekly*” e “*Fortnightly*” evitando redundâncias e distorções nos resultados.

Estas transformações foram realizadas no *Power BI*, através do *Power Query Editor*.

6.4 Modelação de Dados (*Modeling*)

Normalmente, o objetivo desta fase é selecionar algoritmos de *Machine Learning* apropriados e treinar modelos (Lundén et al., 2023). Contudo, dado o foco exploratório e descritivo deste estudo, foi construída a estrutura lógica do modelo de dados no *Power BI*, com o objetivo de permitir uma análise eficiente e flexível do comportamento do consumidor. Neste estudo, a fase de modelação não envolve a criação de modelos preditivos, mas sim a construção do modelo dimensional que suporta a análise no *Power BI*.

Embora esta etapa siga os princípios da modelação dimensional descritos por Kimball & Ross (2002), é importante esclarecer que não se trata da implementação de um *data warehouse* completo. O modelo desenvolvido é uma estrutura lógica interna do *Power BI*, baseada num único *dataset*, e tem uma finalidade essencialmente analítica e ilustrativa.

Com base na estrutura e natureza das variáveis presentes no conjunto de dados, foi adotado um modelo relacional em estrela (*star schema*), amplamente utilizado em contextos de BI pela sua simplicidade e eficiência na análise multidimensional (M. Gonçalves et al., 2025).

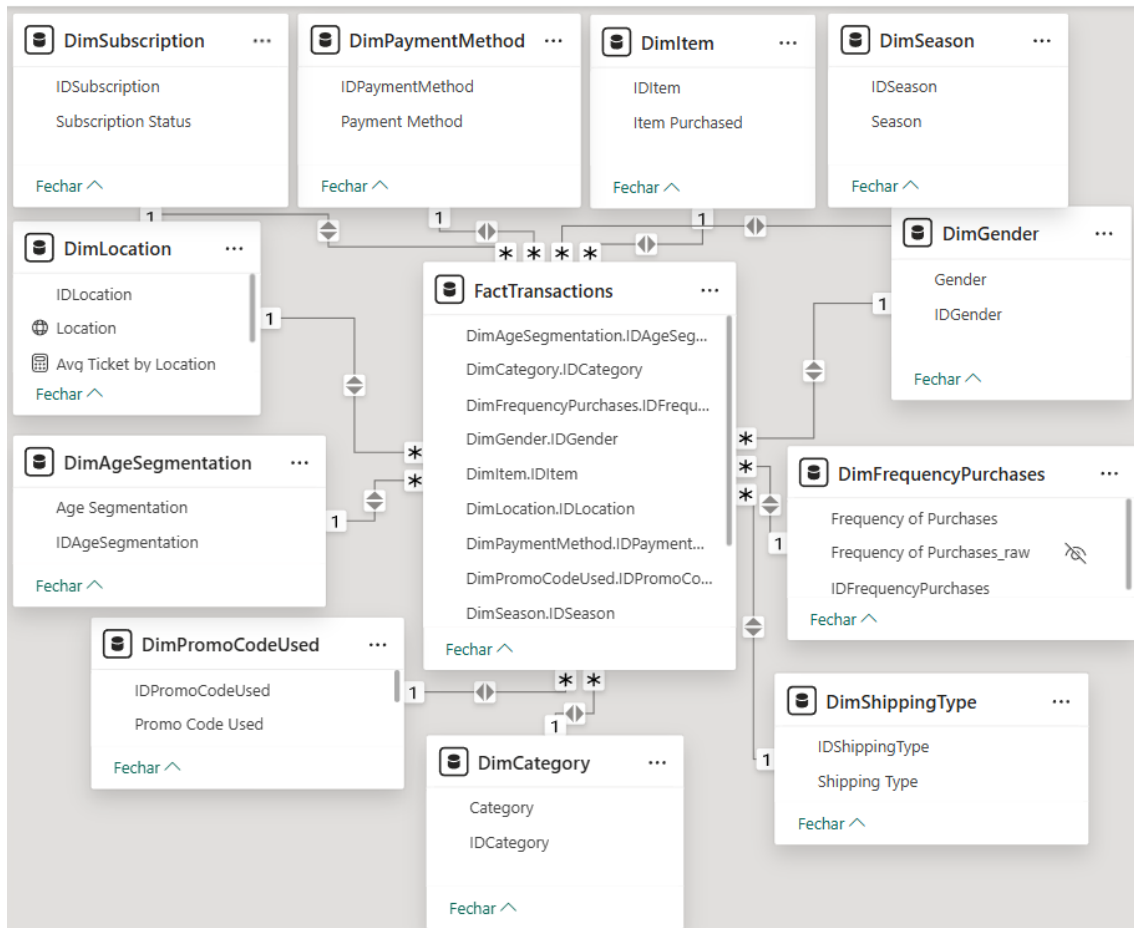


Figura 4- Modelo Relacional em Estrela (Star Schema)

No centro do modelo encontra-se a tabela de factos *FactTransactions*, que agrega os dados transacionais e contém as chaves artificiais que estabelecem ligação com as diversas tabelas de dimensão. Cada dimensão representa um eixo analítico relevante, permitindo segmentar e explorar os dados de forma flexível.

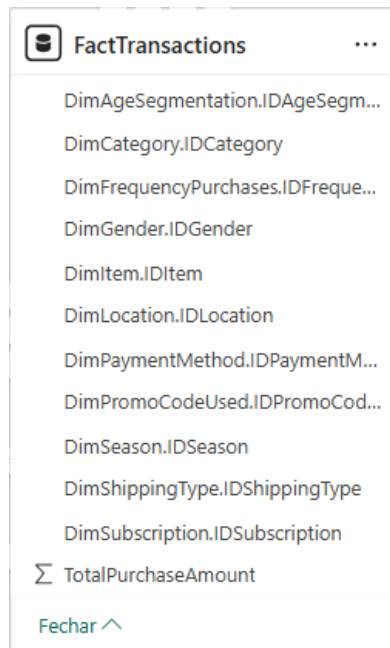
As tabelas de dimensão incluem:

- *DimAgeSegmentation* (*IDAgeSegmentation*, *Age Segmentation*): segmentação etária dos clientes; onde *IDAgeSegmentation* representa um identificador único (chave artificial) do segmento de idade e *Age Segmentation* representa o segmento;
- *DimGender* (*IDGender*, *Gender*): género; *IDGender* é o identificador único e *Gender* representa o género (masculino e feminino);
- *DimLocation* (*IDLocation*, *Location*): localização geográfica dos clientes; *IDLocation* é o identificador único e *Location* representa estados dos Estados Unidos da América;

- DimCategory (*IDCategory, Category*): categoria dos produtos; *IDCategory* é o identificador único da categoria e *Category* representa o tipo de produto;
- DimSeason (*IDSeason, Season*): estação do ano em que ocorreu a compra; *IDSeason* é o identificador único da estação e *Season* indica a estação do ano;
- DimShippingType (*IDShippingType, Shipping Type*): tipo de envio escolhido; *IDShippingType* é o identificador único e *Shipping Type* representa o método de entrega;
- DimPaymentMethod (*IDPaymentMethod, Payment Method*): método de pagamento utilizado nas transações; *IDPaymentMethod* é o identificador único do método e *Payment Method* descreve o tipo de pagamento;
- DimSubscription (*IDSubscription, Subscription Status*): representa o estado da subscrição dos clientes; onde *IDSubscription* é um identificador único da subscrição e *SubscriptionStatus* indica o estado atual;
- DimPromoCodeUsed (*IDPromoCodeUsed*): representa a utilização de códigos promocionais nas transações; *IDPromoCodeUsed* é o identificador único do código, e *PromoCode Used* indica se a compra foi realizada com ou sem promoção;
- DimFrequencyPurchases (*IDFrequencyPurchases, Frequency of Purchases*): frequência de compras; *IDFrequencyPurchases* é o identificador único, *Frequency Of Purchase* representa a frequência (ex: anual, mensal);
- DimItem (*IDItem, ItemPurchased*): itens adquiridos pelos clientes; *IDItem* é o identificador único do item e *ItemPurchased* representa o nome do produto comprado.

Cada uma destas dimensões está ligada à tabela de factos através de uma relação do tipo um-para-muitos (1:N), onde cada valor da dimensão pode estar associado a múltiplas transações. Esta estrutura permite realizar análises cruzadas entre diferentes atributos, como por exemplo: frequência de compra por tipo de envio, receita por categoria de produto, ou comportamento por faixa etária.

Assim, a tabela de factos (*FactTransactions*) refere-se à tabela central do modelo, que regista as transações realizadas pelos clientes.



FactTransactions	
DimAgeSegmentation.IDAgeSegm...	
DimCategory.IDCategory	
DimFrequencyPurchases.IDFreque...	
DimGender.IDGender	
DimItem.IDItem	
DimLocation.IDLocation	
DimPaymentMethod.IDPaymentM...	
DimPromoCodeUsed.IDPromoCod...	
DimSeason.IDSeason	
DimShippingType.IDShippingType	
DimSubscription.IDSubscription	
Σ TotalPurchaseAmount	
Fechar ^	

Figura 5- Tabela de Factos (*FactTransactions*)

Esta tabela constitui o núcleo do modelo analítico, servindo como base para o cálculo de diversas medidas, como o montante total de compras, médias por cliente e percentagens de clientes de alto valor. Estas medidas foram definidas separadamente na tabela *Measures*, recorrendo a expressões DAX no *Power BI*, com o objetivo de enriquecer o modelo e permitir a extração de *insights* relevantes. Estas medidas incluem:

- número total de clientes (*TotalCustomers*)
 - $TotalCustomers = COUNTROWS(FactTransactions)$
- indicadores demográficos como *% Female* e *% Male*
 - $\% \text{ female} = DIVIDE([Female],[TotalCustomers],0)$
 - $\% \text{ male} = DIVIDE([Male],[TotalCustomers],0)$
- valor total de compras (*TotalPurchAmt*)
 - $TotalPurchAmt = SUM(FactTransactions[TotalPurchaseAmount])$
- valor médio de compra por cliente- *ticket* médio (*AvgPurchaseAmt*)
 - $AvgPurchaseAmt = AVERAGE(FactTransactions[TotalPurchaseAmount])$
- número total de compras (*TotalTransactions*)
 - $TotalCustomers = COUNTROWS(FactTransactions)$

- *HighValue* (identifica transações de elevado valor, com base num limiar definido para o valor médio de compra por cliente)
 - $\text{HighValue} = \text{IF}([AvgPurchaseAmt] > 60, 1, 0)$

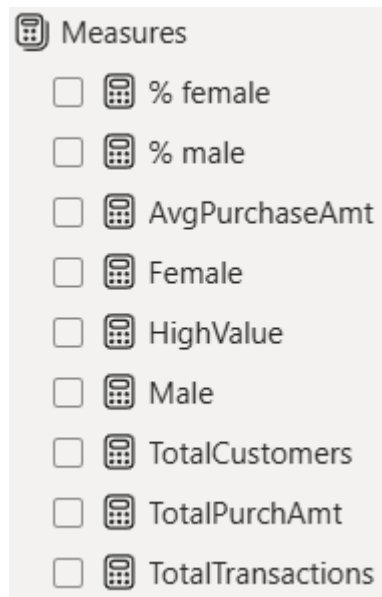


Figura 6- Tabela Measures- medidas DAX

No *dataset* utilizado, cada linha representa simultaneamente uma transação e um cliente. Por este motivo, medidas como *TotalCustomers* e *TotalTransactions* apresentam a mesma expressão DAX ($\text{COUNTROWS}(\text{FactTransactions})$), sendo numericamente equivalentes. A distinção entre ambas é, portanto, conceptual: *TotalCustomers* enfatiza a contagem de clientes, enquanto *TotalTransactions* remete para a leitura analítica associada ao volume de transações.

Estas medidas foram fundamentais para suportar a construção de visualizações interativas no *Power BI*, permitindo a exploração de padrões de consumo, variações por grupo demográfico e tendências de mercado, contribuindo assim para uma análise mais estratégica e orientada por dados.

6.5 Avaliação (*Evaluation*)

Dado que o estudo não envolve modelação preditiva, a fase de avaliação foi adaptada ao contexto descritivo do trabalho, centrado-se na utilidade prática das visualizações construídas.

Normalmente, nesta fase, os modelos treinados são avaliados de acordo com os objetivos de negócio (Lundén et al., 2023). Para isso, são definidas métricas que ajudam a comparar

os modelos e a analisar os seus resultados, muitas vezes recorrendo também à visualização desses dados e das próprias métricas (Schröer et al., 2021). No entanto, quando a análise não tem como foco principal a previsão, como acontece na criação de *dashboards* ou na análise descritiva, a avaliação baseia-se sobretudo na utilidade da solução e na forma como esta é percebida pelo utilizador (Sanabia-Lizarraga et al., 2024).

Neste sentido, a análise desenvolvida procurou explorar as visualizações como apoio à tomada de decisão, com o objetivo de gerar valor para o negócio. A avaliação realizada centrou-se na interpretação dos resultados obtidos através das visualizações, dando ênfase à utilidade, clareza e relevância dos *insights* gerados.

Esta abordagem qualitativa de avaliação está refletida na análise apresentada na secção 7.7, onde se explora a relação entre os *dashboards* desenvolvidos e as questões de investigação. A utilidade dos *dashboards* foi avaliada com base na sua capacidade de responder aos objetivos definidos, reforçando a ligação entre os resultados obtidos e as necessidades do negócio.

6.6 Implementação (*Deployment*)

A fase final da metodologia CRISP-DM visa utilizar os conhecimentos adquiridos no projeto para implementar melhorias na organização (Bokrantz et al., 2023). Esta etapa pode envolver a integração de novas arquiteturas ou modelos em sistemas existentes, ou o desenvolvimento de ações concretas com base nos resultados obtidos através de processos de *data mining* (Schröer et al., 2021).

No entanto, dado que este estudo tem carácter exploratório e utiliza um conjunto de dados sintético, a fase de *deployment* não corresponde à implementação da solução num ambiente organizacional real.

No contexto deste trabalho, a implementação consistiu na criação de *dashboards* interativo no *Power BI*, reunindo os principais indicadores e *insights* obtidos ao longo do processo analítico.

Embora não tenha sido integrado num sistema empresarial, os *dashboards* foram concebidos de forma a poder ser facilmente adaptado e incorporado num ambiente real, oferecendo uma estrutura visual acessível, dinâmica e orientada para a análise do comportamento do consumidor.

CAPÍTULO IV – ANÁLISE DE RESULTADOS

A análise de resultados apresentada nesta secção baseia-se nos dados processados e visualizados através dos *dashboards* interativos criados com o *Power BI*. Esta abordagem permite explorar de forma dinâmica os padrões de comportamento dos consumidores, identificar tendências relevantes e acompanhar os KPIs.

No *dataset* utilizado, cada linha corresponde a uma única compra realizada por um único cliente. Assim, como não existe mais do que uma transação por indivíduo, os termos “cliente”, “consumidor” e “transação” são utilizados de forma equivalente. Esta característica específica do *dataset* elimina a distinção habitual entre estes conceitos e garante coerência na interpretação dos KPIs.

O processo de análise começa com uma visão geral dos KPIs, seguindo com uma segmentação por género, faixa etária e categoria de produto. Posteriormente, são analisados aspetos como a sazonalidade, os métodos de envio e os tipos de pagamento utilizados. Finalmente, são apresentados modelos explicativos, recorrendo à identificação de variáveis influenciadoras e à decomposição hierárquica do valor do cliente.

Esta estrutura de análise oferece uma visão completa e bem fundamentada do comportamento do consumidor, começando por descrever os resultados obtidos e posteriormente articulando-os com a literatura. Para tal, foi realizada uma análise bibliométrica que será detalhada na secção 7.5.

7 Dashboards

Os *dashboards* funcionam como painéis visuais que tornam a análise de dados mais simples e rápida, permitindo identificar padrões e tendências com facilidade, sendo frequentemente desenvolvidos em sistemas de BI como o *Power BI* (Antal et al., 2022). A sua principal função é transformar grandes volumes de dados complexos em informação clara, visual e útil para apoiar a tomada de decisão (Necochea-Chamorro & Larrea-Goycochea, 2023).

A criação de *dashboards* permite identificar padrões e tendências, acompanhar KPIs e apoiar decisões baseadas em dados (Antal et al., 2022). Além disso, permitem integrar informação de várias fontes e partilhá-la entre diferentes níveis da organização, promovendo alinhamento estratégico e maior transparência (C. T. Gonçalves et al., 2023).

De acordo com Necochea-Chamorro & Larrea-Goycochea (2023), um *dashboard* é uma interface visual que reúne, organiza e apresenta dados de forma interativa, oferecendo

uma visão clara do desempenho de uma empresa ou processo específico, facilitando uma análise rápida e decisões mais informadas.

7.1 Dashboard 1 — Visão Geral e Segmentação Demográfica

As primeiras visualizações foram criadas com o objetivo de apresentar uma visão geral do comportamento do consumidor, destacando os principais indicadores demográficos e financeiros. Para isso, foram utilizadas visualizações de cartões, gráficos de barras agrupadas e empilhadas, bem como filtros interativos por faixa etária e localização. No *dashboard*, o valor do montante médio de compra por transação é apresentado em dólares americanos em conformidade com o definido no *dataset* original.




Figura 7- Dashboard 1 — Visão Geral e Segmentação Demográfica

Neste *dashboard*, os cartões apresentam os principais KPIs do estudo: o número total de clientes (3900), o montante total de vendas gerado (\$233K), o ticket médio por transação (\$59,76), bem como a distribuição por género. Verifica-se que 68% dos consumidores são do sexo masculino (2652 clientes), enquanto 32% são do sexo feminino (1248 clientes), evidenciando uma predominância masculina no perfil de clientes da organização.

No gráfico de barras referente ao valor de vendas por género, observa-se que os homens geram uma receita total de \$158.000, enquanto as mulheres contribuem com \$75.000. Esta diferença significativa reforça a importância de segmentar campanhas e estratégias comerciais com base no género, especialmente em categorias de produto com maior adesão masculina.

A análise por faixa etária revela que os adultos representam o grupo mais expressivo em número de compras (2956), seguidos pelos jovens adultos (878) e pelos seniores (66). Esta segmentação permite compreender quais os grupos etários mais ativos e relevantes para a organização, sendo os adultos o principal público-alvo em termos de volume de transações.

No gráfico de valor de vendas por categoria de produto, destacam-se o vestuário (“*clothing*”) como a categoria responsável pela maior fatia de receita (\$104.000), evidenciando-se como a categoria mais rentável. Seguem-se os acessórios (“*accessories*”), com um desempenho financeiro igualmente relevante (\$74.000). Já as categorias calçado (“*footwear*”) e vestuário de exterior (“*outerwear*”) revelam menor impacto financeiro, sendo as menos representativas em termos de receita. Esta distribuição permite perceber quais os tipos de produto com maior retorno económico, servindo de base para orientar decisões estratégicas sobre campanhas promocionais, gestão de *stock* e posicionamento comercial (Necochea-Chamorro & Larrea-Goycochea, 2023).

No gráfico que representa o número de compras por categoria e género, observa-se uma predominância dos consumidores do género masculino em todas as categorias, com destaque para o vestuário, onde os homens realizaram mais do dobro das compras face às mulheres (1181 vs. 556). Esta tendência reforça a ideia de um perfil de consumo masculino mais ativo, sugerindo desenvolver campanhas mais segmentadas e alinhadas com as preferências de cada género.

O *dashboard* inclui ainda filtros interativos por faixa etária e localização, permitindo ao utilizador explorar os dados de forma personalizada e aprofundar a análise por segmentos específicos. Esta funcionalidade reforça o carácter dinâmico da ferramenta de BI, promovendo uma leitura mais rica e contextualizada dos dados.

7.2 Dashboard 2 — Métodos de Pagamento, Envio e Sazonalidade

O segundo *dashboard* desenvolvido tem como objetivo analisar o comportamento dos consumidores em função da sazonalidade e dos métodos de pagamento utilizados. Esta visualização permite compreender como as preferências de compra variam ao longo do ano e identificar padrões associados a diferentes faixas etárias, tipos de envio e categorias de produto.

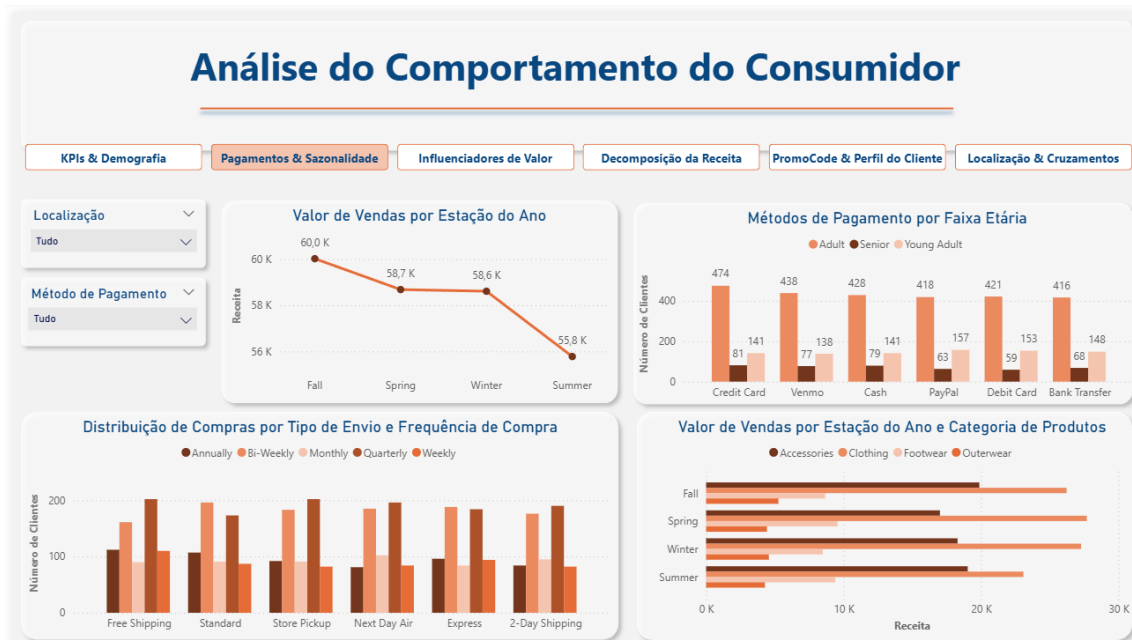


Figura 8- Dashboard 2 — Métodos de Pagamento, Envio e Sazonalidade

A primeira componente do painel apresenta o gráfico de valor de vendas por estação do ano, onde se observa uma ligeira variação nos montantes totais de receita entre as diferentes estações. O outono (“*fall*”) destaca-se como o período com maior volume de vendas (\$60.000), seguida pela primavera (“*spring*”) e inverno (“*winter*”), com valores semelhantes entre si, e por último o verão (“*summer*”) com o menor valor. Esta tendência sugere que campanhas promocionais e estratégias comerciais poderão ser mais eficazes se alinhadas com os períodos de maior consumo, nomeadamente no outono. Pois, segundo Shwawreh & Awamleh, (2025), o sucesso do *marketing* está fortemente ligado à capacidade de adaptar as estratégias às dinâmicas do mercado, incluindo a sazonalidade.

O gráfico de métodos de pagamento por faixa etária mostra, de forma clara, as preferências dos consumidores em função da idade. Os adultos optam mais pelo uso de cartão de crédito (“*credit card*”) e do *Venmo*, que é uma plataforma muito utilizada nos

Estados Unidos para fazer pagamentos móveis. Por sua vez, os jovens adultos demonstram preferência por *PayPal* e pelo cartão de débito (“*debit card*”).

Na análise de distribuição de compras por tipo de envio e frequência, observa-se que o envio gratuito (“*free shipping*”) e levantamento na loja (“*store pickup*”) são as opções mais escolhidas por clientes que compram trimestralmente (“*quarterly*”), com 202 registos em cada categoria. O envio “*standard*” e a entrega rápida (“*next day air*”) também apresentam números relevantes para essa mesma frequência, o que sugere uma preferência por soluções convenientes associadas ao equilíbrio entre custo e rapidez. Por outro lado, as compras anuais (“*annually*”) e mensais (“*monthly*”) são menos frequentes em todas as categorias, o que indica que a maioria dos consumidores realiza compras com regularidade. Assim, este padrão revela uma tendência de consumo recorrente e fidelizado, principalmente nas opções de envio gratuito e levantamento na loja. Esta informação é útil porque permite avaliar o impacto logístico das escolhas dos clientes e ajustar a oferta de modalidades de envio de acordo com os seus hábitos.

Por fim, o gráfico que cruza o valor de vendas com a estação do ano e a categoria de produto permite observar dois aspetos importantes: o que comprou e quando comprou. Os dados mostram que a categoria vestuário tem maior receita na primavera e inverno, enquanto o vestuário de exterior, apesar de ser o segmento com menor volume de vendas, apresenta o seu melhor desempenho no outono e mantém uma *performance* equilibrada nas restantes estações. Esta informação é valiosa para orientar decisões de stock, campanhas sazonais e alocação de recursos por categoria.

O *dashboard* inclui ainda filtros interativos por localização e método de pagamento, permitindo ao utilizador explorar os dados de forma personalizada e aprofundar a análise por segmentos específicos.

7.3 Dashboard 3 — Identificação de Variáveis Influenciadoras

O terceiro *dashboard* desenvolvido tem como objetivo identificar os fatores que influenciam positivamente o valor dos consumidores, ou seja, os elementos que estão associados à classificação de clientes como *High Value*. Esta análise é fundamental para compreender os padrões que potenciam o desempenho financeiro de determinados segmentos e para apoiar decisões estratégicas orientadas à retenção e valorização de clientes.




Figura 9- Dashboard 3 — Identificação de Variáveis Influenciadoras

A componente central do painel apresenta a questão orientadora: “O que influencia *High Value*?”, com a opção “Aumento”, permitindo uma abordagem explicativa que visa identificar os atributos mais relevantes na definição de clientes de elevado valor.

Embora a métrica *High Value* seja tecnicamente definida ao nível da transação, no *dataset* utilizado corresponde diretamente ao nível do cliente, dado que cada indivíduo realiza apenas uma compra. O limiar \$60 adotado na classificação *High Value* resulta do valor médio de compra, servindo como referência para distinguir consumidores com um gasto superior ao comum.

Na secção de “Principais Influenciadores”, são destacados os fatores que mais contribuem para a probabilidade de um cliente não pertencer ao segmento *High Value*. Os principais influenciadores identificados foram:

- O segmento etário “*Adult*”, com maior impacto positivo na classificação;
- A categoria de produto “*Clothing*”, associada a transações de maior valor;
- O género masculino, que apresenta uma tendência superior para compras de elevado montante.

Estes padrões sugerem que consumidores adultos do sexo masculino, com preferência por vestuário, representam um perfil estratégico para a organização, sendo mais propensos a realizar transações de maior valor.

O gráfico de barras à direita reforça esta análise ao apresentar a média da medida *HighValue* por faixa etária, evidenciando que o grupo “*Adult*” apresenta o valor médio mais elevado, seguido por “*Young Adult*” e “*Senior*”. Esta visualização permite uma leitura comparativa entre segmentos demográficos, facilitando a identificação de públicos com maior propensão para gerar valor, o que pode orientar ações de *marketing* e estratégias de fidelização.

Este *dashboard* oferece uma abordagem diagnóstica e orientada para a valorização do cliente, permitindo à organização compreender os fatores que impulsionam o valor gerado por diferentes perfis. A identificação de influenciadores positivos é essencial para o desenvolvimento de estratégias segmentadas, personalização da oferta e maximização da rentabilidade.

7.4 Dashboard 4 — Árvore de Decomposição da Receita

O quarto *dashboard* desenvolvido tem como objetivo representar de forma visual e interativa a decomposição da receita total gerada pelos consumidores, cruzando múltiplas dimensões demográficas e comportamentais. Para tal, foi utilizado o visual da árvore de decomposição, que permite visualizar o fluxo de valor entre diferentes atributos, facilitando a identificação de padrões e relações entre variáveis.

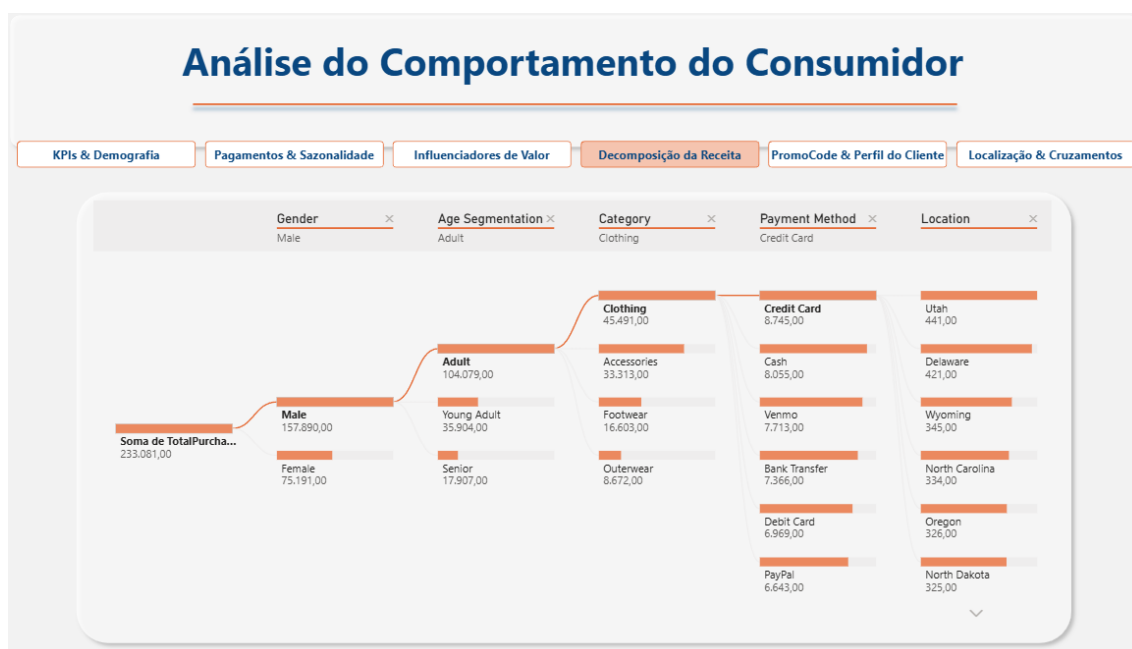


Figura 10- Dashboard 4 — Árvore de Decomposição da Receita

A análise inicia-se com a segmentação por género, onde se observa que os consumidores do sexo masculino são responsáveis por um total de \$157.890 em compras. Este valor é

posteriormente desagregado por faixa etária, revelando que os adultos (“*adult*”) concentram a totalidade dessa receita, o que indica uma predominância clara de adultos do sexo masculino no perfil de clientes mais rentáveis.

Ao nível da categoria de produto, verifica-se que a maior parte da receita provém de vestuário, com um total de \$45.491, seguido por acessórios (“*accessories*”), com \$33.313. Os dados revelam uma preferência clara por artigos de moda, com o vestuário a destacar-se como a principal fonte de receita dentro deste segmento.

A análise segue com o método de pagamento, onde se observa uma distribuição equilibrada entre diferentes opções. O cartão de crédito (“*credit card*”) aparece como o mais utilizado, com um total de \$8.745 em transações. Este valor indica que os homens adultos tendem a escolher formas de pagamento mais práticas.

Por fim, ao analisar a localização geográfica das compras, nota-se uma dispersão moderada, com maior concentração nos estados de Utah (\$441), Delaware (\$421) e Wyoming (\$345). Esta informação é útil para definir estratégias de expansão territorial, distribuir recursos de forma mais eficiente e adaptar campanhas às características de cada região.

O uso da árvore de decomposição neste *dashboard* permite uma leitura fluida e intuitiva dos dados, evidenciando como diferentes atributos se interligam e contribuem para o valor total gerado. De forma geral, o gráfico revela que o perfil de maior consumo é composto por homens adultos, com grande inclinação para o setor de vestuário, preferência por pagamentos com cartão de crédito e maior representatividade em alguns estados específicos. Esta informação é fundamental para orientar estratégias de segmentação, marketing direcionado e políticas de fidelização, permitindo à empresa alinhar as suas ações com os padrões de comportamento do seu público mais lucrativo.

7.5 Dashboard 5 — PromoCode & Perfil do Cliente

O quinto *dashboard* desenvolvido tem como objetivo analisar o impacto da utilização de códigos promocionais (“*PromoCode*”) no comportamento de compra dos consumidores, bem como caracterizar o perfil demográfico dos utilizadores destas promoções. Esta análise permite compreender a eficácia das campanhas promocionais e identificar os segmentos que mais beneficiam ou aderem a este tipo de incentivo.

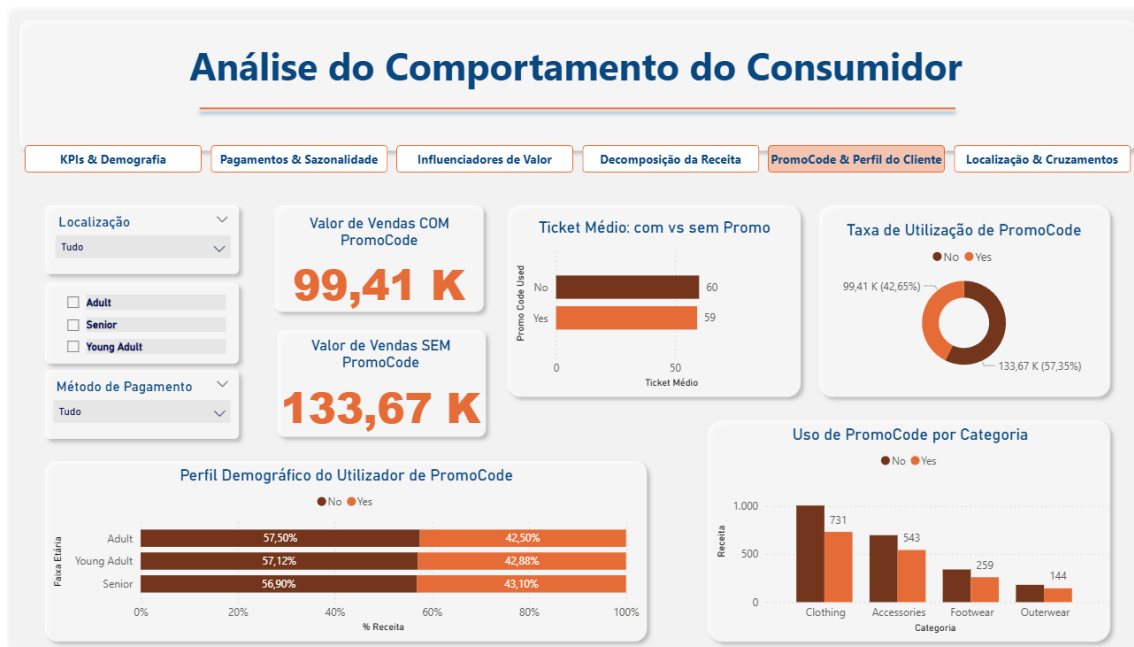


Figura 11- Dashboard 5 — PromoCode & Perfil do Cliente

A primeira componente do painel apresenta os indicadores de receita, distinguindo entre o valor total de vendas com “PromoCode” (\$99.41K) e sem “PromoCode” (\$133.67K). Esta diferença revela que, apesar de uma adesão significativa às promoções, a maior parte da receita continua a ser gerada por transações sem utilização de códigos promocionais. Este dado sugere que as promoções funcionam como complemento estratégico, mas não substituem o valor gerado por compras habituais.

O gráfico que compara o *ticket* médio com e sem *PromoCode* mostra que os consumidores que usam códigos promocionais gastam, em média, menos por compra (\$59) do que aqueles que não os utilizam (\$60). Esta diferença é comum em campanhas promocionais, uma vez que os descontos costumam atrair clientes mais sensíveis ao preço ou compras de menor valor (Abdel Wahab et al., 2023). Contudo, pode também representar uma oportunidade para aumentar o valor médio das transações com *PromoCode*, por exemplo, através de estratégias como *upselling* ou a criação de conjuntos de produtos que combinem entre si (Alawadh & Barnawi, 2024).

A taxa de utilização de *PromoCode* é apresentada em percentagem, sendo que 43% das compras (valor que equivale igualmente a 43% dos clientes, dado que cada cliente tem apenas uma transação), enquanto 57% não utilizaram *PromoCode*. Refletir sobre a taxa de adesão é importante porque permite avaliar o impacto das campanhas e pode ser

analisado por localização ou faixa etária, usando os filtros interativos disponíveis no painel.

A análise do perfil demográfico dos utilizadores de *PromoCode* mostra uma distribuição equilibrada entre os diferentes grupos etários. Os adultos representam 42,5% dos utilizadores, os jovens adultos 42,88% e os seniores 43,10%. Esta segmentação permite perceber que a adesão à *PromoCode* não está concentrada num único grupo, mas distribuída de forma relativamente homogénea, o que reforça a importância de manter campanhas promocionais adaptadas a diferentes públicos.

No gráfico de uso de *PromoCode* por categoria de produto, verifica-se que o vestuário é a categoria com maior número de utilizações (731), seguido por acessórios (543) e calçado (259). Esta distribuição sugere que os consumidores estão mais propensos a utilizar *PromoCode* em categorias relacionadas com moda e estilo pessoal, o que pode orientar decisões sobre onde aplicar campanhas promocionais com maior retorno.

O *dashboard* inclui ainda filtros interativos por localização, faixa etária e método de pagamento, permitindo ao utilizador explorar os dados de forma personalizada e aprofundar a análise por segmentos específicos.

7.6 Dashboard 6 — Localização e Cruzamentos

O último *dashboard* desenvolvido tem como objetivo analisar o comportamento dos consumidores em função da sua localização geográfica, cruzando esta variável com indicadores como o ticket médio, os métodos de pagamento utilizados e a adesão a códigos promocionais. Esta abordagem permite identificar padrões regionais de consumo e adaptar estratégias comerciais às especificidades de cada mercado.

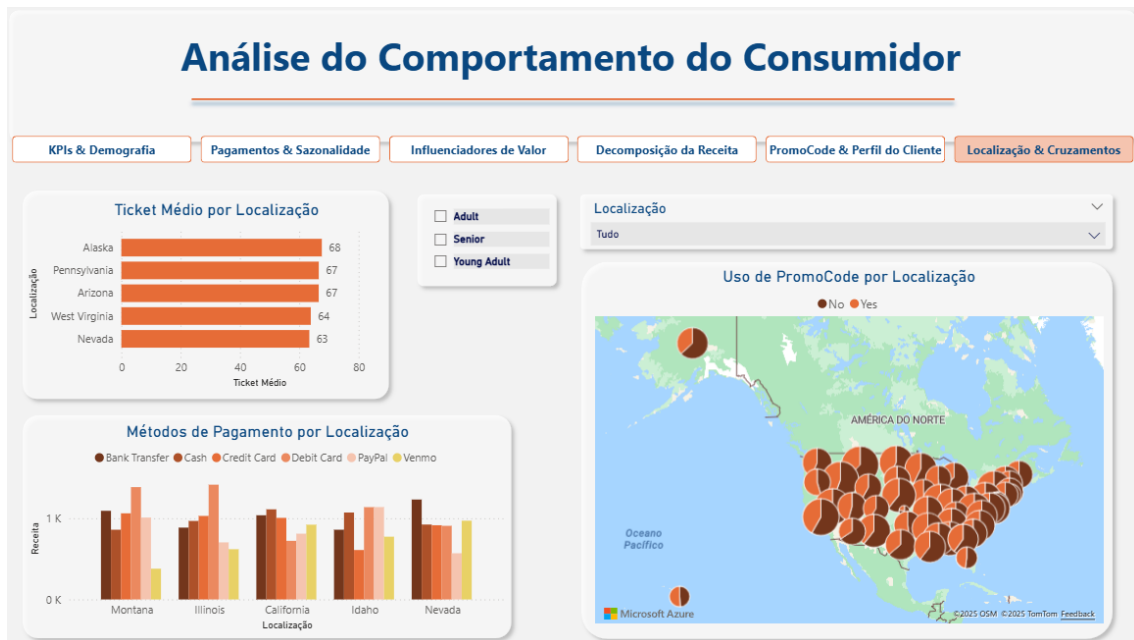


Figura 12- Dashboard 6 — Localização e Cruzamentos

A primeira componente do *dashboard* apresenta o ticket médio por localização, sendo apenas exibidas as cinco regiões com valores médios de transação mais altos. Desta forma, os estados do Alaska, Pennsylvania, Arizona, West Virginia e Nevada destacam-se pelo valor médio gasto por cliente, permitindo uma comparação entre regiões. Esta métrica ajuda a perceber o poder de compra e os hábitos de consumo em cada local, revelando quais os mercados com maior capacidade de gasto individual. Esta informação é útil para definir estratégias de preço ajustadas a cada região (Corboş et al., 2023), bem como para orientar campanhas promocionais e políticas de distribuição adaptadas às características de cada mercado (Giannakopoulos et al., 2024).

O gráfico que analisa os métodos de pagamento por localização complementa esta análise, ao mostrar as preferências dos consumidores em cada estado, seja pelo uso de cartão de crédito, débito ou meios digitais. Este gráfico não apresenta as mesmas localizações do anterior, pois representa os cinco estados com maior volume monetário total de compras, e não o *ticket* médio. Assim, apenas Nevada se destaca em ambas as análises, sugerindo que este estado combina alto gasto médio por transação com volume total de compras elevado, tornando-se um mercado de especial interesse estratégico.

A comparação entre ambos os gráficos permitem inferir que regiões com ticket médio elevado nem sempre correspondem às que geram maior volume de receita, indicando diferenças nos padrões de consumo e na quantidade de clientes ativos.

A utilização de *PromoCode* por localização é exibida por meio de um mapa interativo, no qual marcadores circulares indicam a intensidade da adesão a códigos promocionais em diferentes regiões. Esta representação geográfica possibilita a identificação de áreas mais recetivas a campanhas promocionais, sendo especialmente eficaz para segmentar campanhas de *marketing* e avaliar o retorno de iniciativas comerciais por região.

O *dashboard* inclui ainda filtros interativos por faixa etária e localização, permitindo ao utilizador explorar os dados de forma personalizada e aprofundar a análise por segmentos específicos.

7.7 Relação entre os *Dashboards* e as Questões de Investigação

A presente investigação teve como objetivo principal analisar o comportamento do consumidor com base em dados de compras, de forma a identificar padrões relevantes que sustentem decisões estratégicas com recurso ao BI. Para tal, e conforme apresentado anteriormente, foram desenvolvidos diversos *dashboards* interativos no *Power BI*, cada um com foco específico, que permitiram responder às questões definidas no subcapítulo 6.1- Compreensão do Negócio (*Business Understanding*), sendo estas apresentadas de seguida.

Esta análise corresponde à fase de avaliação do modelo analítico, conforme definido no CRISP-DM. Dado que o presente estudo não envolveu modelos preditivos, a avaliação assumiu uma abordagem qualitativa, centrando-se na utilidade dos *dashboards* para responder às questões de investigação. Assim, a eficácia do modelo foi avaliada com base na capacidade das visualizações em gerar insights relevantes, claros e alinhados com os objetivos de negócio previamente definidos.

7.7.1 Quais são os perfis mais comuns de consumidores?

Esta questão foi abordada principalmente através do *dashboard* “KPIs & Demografia”, que apresenta indicadores como o total de clientes, a distribuição por género, a faixa etária e o ticket médio por transação. A análise permitiu identificar que a maioria dos consumidores são adultos do sexo masculino, com maior representatividade na receita total. A segmentação por idade e género revelou padrões de consumo distintos, permitindo caracterizar os perfis mais recorrentes e relevantes para a organização.

7.7.2 Que categorias de produto têm maior adesão por gênero, faixa etária ou método de pagamento?

Esta questão foi explorada em vários *dashboards*:

- O *dashboard* “Número de Compras por Categoria e Gênero” apresenta a distribuição de compras por categoria (acessórios, vestuário, calçado e vestuário de exterior) segmentada por gênero, evidenciando preferências distintas entre homens e mulheres.
- O *dashboard* “Métodos de Pagamento por Faixa Etária” permite observar quais os métodos mais utilizados por diferentes grupos etários.
- O *dashboard* “Valor de Vendas por Estação do Ano e Categoria de Produtos” complementa esta análise ao mostrar a variação da receita por categoria de produto ao longo das estações do ano, revelando padrões sazonais que influenciam a adesão por tipo de produto.

Estas visualizações permitiram cruzar variáveis demográficas com comportamentos de compra, oferecendo uma visão detalhada sobre as preferências dos consumidores.

7.7.3 Existem padrões temporais ou regionais no consumo?

Esta questão foi respondida pelos *dashboards* “Localização & Cruzamentos” e “*PromoCode* & Perfil do Cliente”, que apresentam informações segmentadas por estado/região, como o valor médio por localização, os métodos de pagamento mais utilizados em cada estado e a taxa de utilização de *PromoCode*. A análise apresentou diferenças consideráveis entre as regiões, como um ticket médio mais alto em estados como o Alaska e um uso mais frequente de certos métodos de pagamento em estados como Nevada ou Califórnia.

Além disso, o *dashboard* “Receita por Estação e Categoria” permitiu identificar padrões sazonais, no qual foi possível concluir que determinadas categorias de produto geram mais receita em estações específicas, como, por exemplo, roupa no inverno ou acessórios na primavera.

Em suma, os *dashboards* desenvolvidos ilustram de forma clara como o comportamento do consumidor pode ser analisado através de BI, respondendo diretamente às questões de investigação e contribuindo para uma análise orientada para o negócio.

8 Análise Bibliométrica das Tendências de Compra

Nos dias de hoje, com o crescente volume e complexidade de dados sobre o comportamento do consumidor, as empresas têm o desafio de entender melhor as necessidades e vontades dos seus clientes (Xu et al., 2024). Como tal, torna-se essencial identificar as áreas mais exploradas e as lacunas ainda existentes na investigação científica (Basu et al., 2023). Neste sentido, foi realizada uma análise bibliométrica com recurso ao *software VOSviewer*, com o objetivo de apresentar visualmente as principais tendências de investigação e reforçar o enquadramento teórico desta dissertação.

Segundo Corboş et al. (2023), a análise bibliométrica é uma técnica quantitativa e organizada que ajuda a compreender o panorama científico de uma determinada área. De acordo com o autor, esta é uma abordagem que se baseia em dados estatísticos de publicações académicas para identificar tendências de investigação, autores e instituições com maior impacto, trabalhos mais citados e também as lacunas que ainda existem no conhecimento.

Neste estudo, a análise bibliométrica permitiu não só identificar os tópicos mais relevantes na literatura recente, como também foi possível compará-los com os dados analisados no *Power BI*.

8.1 Metodologia da Análise Bibliométrica- VOSviewer e Web of Science

A base de dados utilizada para a pesquisa de artigos científicos foi a *Web of Science* (WoS), e a ferramenta utilizada para a análise e visualização dos dados foi o *VOSviewer*, um *software* especializado no mapeamento da coocorrência de palavras-chave semelhantes.

A pesquisa foi orientada pelos tópicos identificados nos *dashboards* desenvolvidos no *Power BI*, com especial foco nas seguintes dimensões:

- Género e comportamento de consumo;
- Métodos de pagamento e faixa etária;
- Preferências de envio;
- Sazonalidade e comportamento de compra;
- Categorias de produtos e decisões de compra;
- Localização no consumo.

8.1.1 Critérios de Pesquisa

Para cada um dos temas, foram definidos termos de pesquisa específicos, aplicados exclusivamente nos títulos dos artigos (campo “*Title*”), de modo a garantir um foco mais direto no conteúdo principal dos estudos. Foi adotado este método de pesquisa pois, ao utilizar o campo “*Topic*”, o número de artigos obtidos era extremamente elevado. Desta forma, para cada um dos temas, foi utilizada a seguinte estrutura de pesquisa (neste exemplo, referente ao método de envio):

"shipping method" (Title) or "delivery preference" (Title) and "consumer behavior" (Title) or "online shopping" (Title) and Business or Management or Economics (Web of Science Categories) and 2025 or 2024 or 2023 or 2022 or 2021 (Publication Years) and 2025 or 2024 or 2023 or 2022 or 2021 (Publication Years) and Open Access and Business or Economics or Management (Web of Science Categories)

Figura 13- Termos de Pesquisa- Web of Science

Os filtros aplicados em todas as pesquisas foram:

- Período de publicação: 2021 a 2025
- Categorias da WoS: *Business*, *Economics* e *Management*
- Apenas artigos de acesso aberto (*Open Access*)

Esta abordagem tem como objetivo garantir a atualidade dos estudos analisados, bem como o seu enquadramento em áreas relevantes para a tomada de decisão nas empresas.

8.1.2 Exportação e Análise dos Dados

Os dados foram exportados em formato *plain text* e depois importados para o *software VOSviewer*, com o objetivo de criar mapas de coocorrência de termos, incluindo palavras-chave, *abstracts* e títulos. Estes mapas usam agrupamentos visuais com diferentes cores para destacar as principais linhas de pesquisa, os termos mais frequentes e as ligações entre eles dentro de cada tema.

8.2 Clusters de Tendências Identificados

Os mapas gerados no *VOSviewer* permitem identificar, através de *clusters* de cores distintas, as principais linhas de investigação, termos mais recorrentes e sua relação entre si dentro de cada tema.

Cada visualização, apresentada de seguida, representa graficamente a estrutura conceitual da literatura do respetivo tema, evidenciando os termos com maior frequência e nível de ligação com outros conceitos. As cores refletem agrupamentos (*clusters*) de tópicos correlacionados, enquanto o tamanho dos nós representa a frequência de ocorrência de cada termo.

8.2.1 Género e Comportamento de Consumo




Figura 14- Mapa de coocorrência de termos relacionados com o género e comportamento de consumo

O gráfico apresenta o termo “*consumer behavior*” (comportamento do consumidor) como nó central, evidenciando a sua importância na literatura da atualidade. Os *clusters* identificados agrupam conceitos como “*impact*”, “*consumption*” e “*sustainability*”, que se relacionam entre si e refletem preocupações associadas ao consumo e às suas consequências. Por outro lado, surgem também os termos como “*technology*”, “*perceptions*”, “*loyalty*” e “*satisfaction*”, que representam uma vertente mais ligada à experiência e à relação do consumidor com as marcas.

Apesar do foco estar no comportamento do consumidor, observa-se a ausência de uma ligação direta com o tema género. Esta ausência pode indicar que, embora o género influencie comportamentos e decisões de compra, conforme analisado nos *dashboards*, este fator ainda não é abordado de forma central nas publicações analisadas.

8.2.2 Método de Pagamento e Faixa Etária




Figura 15- Mapa de coocorrência de termos relacionados com métodos de pagamento e faixa etária

O gráfico evidencia dois grupos de termos principais, representados por *clusters* diferentes. De um lado, surge o *cluster* verde, centrado em conceitos como “*age group*”, “*contribution*” e “*support*”, que remetem para características demográficas e aspetos relacionados com o perfil dos consumidores. Do outro lado, está representado o *cluster* vermelho que reúne termos como “*payment method*”, “*cryptocurrency*” e “*bitcoin*”, refletindo o interesse crescente em novas formas de pagamentos digitais.

A ligação entre ambos os *clusters* é visível, mas pouco acentuada, o que sugere que a relação entre a idade dos consumidores e os métodos de pagamento, especialmente os digitais, ainda é pouco explorada na literatura.

8.2.3 Preferências no Método de Envio

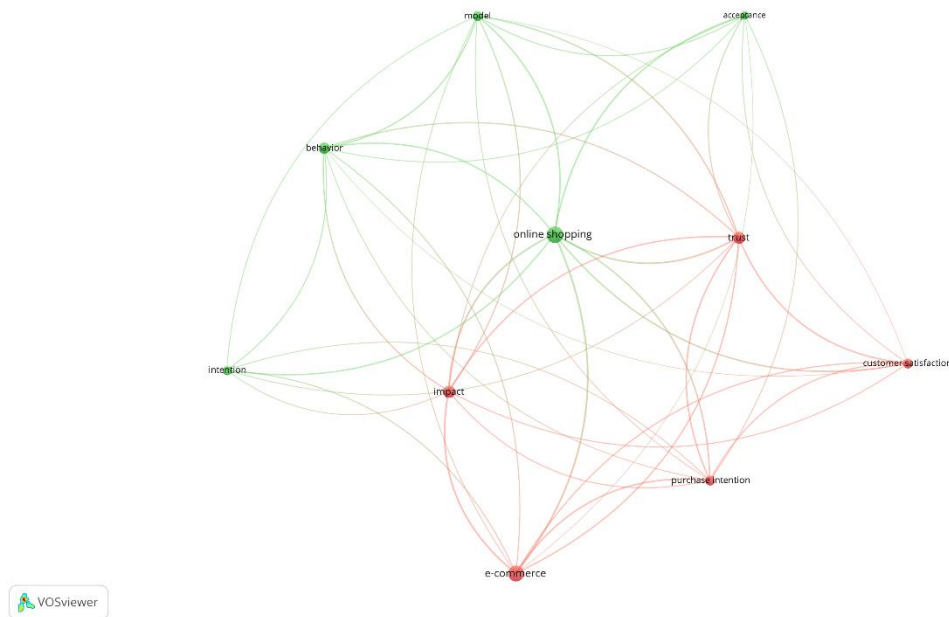


Figura 16- Mapa de coocorrência de termos relacionados com a preferência nos métodos de envio

O gráfico mostra a relação entre diferentes conceitos associados às compras online e à preferência de envio. Sendo que, os *clusters* revelam duas áreas principais: uma mais voltada para o comportamento e a intenção do consumidor (verde) e outra relacionada com a experiência e confiança no processo de compra (vermelho).

O termo “*online shopping*” destaca-se como o nó central, interligando-se com “*trust*”, “*customer satisfaction*”, “*purchase intention*” e “*e-commerce*”, o que evidencia que a confiança e a satisfação do cliente influenciam diretamente as intenções de compra e a escolha do método de envio, conforme defendido por Agag et al. (2024) e Guo & Zhai (2022).

8.2.4 Sazonalidade e Comportamento de Compra





Figura 17- Mapa de coocorrência de termos relacionados com a sazonalidade e o comportamento do consumidor

O gráfico representa a relação entre sazonalidade e o comportamento do consumidor. Observam-se dois grupos distintos: o *cluster* vermelho, centrado em termos como “*online shopping*”, “*online shopping behavior*”, “*customer*” e “*crisis*”, e o *cluster* verde, que inclui “*seasonality*”, “*price*”, “*year*” e “*household*”.

As ligações entre ambos os *clusters*, geridas pelo termo “*time*”, mostram que os estudos tendem a relacionar o comportamento de compra com fatores temporais, como épocas do ano ou variações de preço. Esta ligação sugere que a sazonalidade influencia o comportamento do consumidor, embora de forma indireta.

8.2.5 Categorias de Produtos e Decisões de Compra




Figura 18- Mapa de coocorrência de termos relacionados com as categorias de produtos e decisões de compra

O gráfico mostra as relações entre as categorias de produtos e as decisões de compra. No centro, o termo “*decision*” destaca-se como elemento de ligação entre diferentes grupos de conceitos.

Os *clusters* representam três áreas principais: o verde, que agrega termos como “*consumer*”, “*factor*” e “*purchase decision*”, associados às motivações e critérios de escolha; o vermelho, ligado a “*influence*”, “*brand awareness*” e “*customer*”, que reflete o impacto das marcas e da percepção do consumidor; e o azul, composto por “*product*” e “*product category*”, que remete para a importância das características e tipos de produtos na decisão de compra.

A interligação entre estes *clusters* demonstra que as decisões de compra resultam da combinação de vários fatores, refletindo a complexidade do comportamento do consumidor.

8.2.6 Localização no Consumo




Figura 19- Mapa de coocorrência de termos relacionados com o impacto da localização no consumo

O gráfico apresenta as relações entre os principais conceitos associados à localização no comportamento do consumidor. O termo “*impact*” ocupa uma posição central, conectando-se com “*policy*”, “*growth*”, “*efficiency*” e “*cities*”, o que demonstra que as políticas e o desenvolvimento urbano estão frequentemente ligados à forma como a localização influencia o consumo.

Os *clusters* identificam diferentes perspectivas: o vermelho associa-se ao crescimento e eficiência, o verde faz relaciona o impacto com o contexto urbano (“*cities*”), e o azul destaca “*regional differences*”, demonstrando que o comportamento do consumidor varia consoante a localização. Com efeito, estas ligações sugerem que a localização continua a ser um fator relevante, refletindo diferenças regionais que afetam tanto as preferências como as oportunidades de consumo.

8.3 Comparação com os Resultados do *Power BI*

O comportamento do consumidor é influenciado por uma complexa interação de fatores racionais e emocionais, que podem variar dependendo do contexto da compra, do produto e das características individuais do consumidor (Kunc et al., 2024). Nesse sentido, a análise de segmentação ou *clustering* é uma ferramenta utilizada para identificar grupos distintos com base nas suas semelhanças, e pode ser aplicada para estudar as suas

características ao longo de dimensões conhecidas, como fatores comportamentais e sociodemográficos (Taghikhah et al., 2021).

A presente análise procura estabelecer uma ligação entre os dados recolhidos através dos *dashboards* interativos e a literatura científica, com o objetivo de identificar padrões de comportamento associados a variáveis como o género, a localização, a idade, os métodos de pagamento e de envio.

Embora o termo “*gender*” (género) não tenha surgido com destaque no respetivo mapa gerado pelo VOSviewer, o autor Abdel Wahab et al. (2023) defende que o género é muitas vezes considerado um dos fatores mais importantes para determinar os processos de tomada de decisão. A forma como homens e mulheres abordam as decisões de compra é distinta, especialmente em ambientes digitais (Wijaya, 2022). Tal tendência é confirmada a partir dos dados analisados, isto é: dos 3900 clientes, 68% são homens e geram 158000 dólares, enquanto as mulheres representam 32% dos consumidores e geram 75000 dólares. Esta diferença reforça a ideia de Kunc et al. (2024), segundo a qual os homens apresentam uma abordagem mais direta e rápida ao processo de compra. Esta característica pode ajudar a explicar o facto de serem os homens a fazer mais compras. A categoria mais popular, vestuário, é também a mais consumida por clientes do sexo masculino, o que reforça ainda mais esta conclusão.

Outro fator importante na análise do comportamento do consumidor é a localização geográfica (Zwart, 2022). De acordo com Zwart (2022) e Pinkovetskaia et al. (2022), fatores como o rendimento médio da população, o nível de digitalização e estabilidade económica da região influenciam diretamente os hábitos de consumo e os métodos de pagamento utilizados. Nos dados observados, a variável *Location* revelou-se preditiva, destacando-se a categoria ‘Connecticut’, que apresenta um maior número de clientes com baixo valor de compra. Adicionalmente, dos cinco estados que mais receita geram, verifica-se que Nevada e Califórnia apresentam elevada utilização do método digital de pagamento *Venmo*, assim como também o estado de Idaho demonstra uma elevada utilização de outro método de pagamento digital, o *Paypal*. Assim, sugere-se uma possível correlação entre grau de digitalização regional e escolha de meios de pagamento, em linha com as conclusões de Pinkovetskaia et al. (2022).

A variável idade representa igualmente uma forte associação com padrões de pagamento e consumo (Abdel Wahab et al., 2023). Segundo Kubiczek (2022), a idade é um dos

principais fatores que influenciam a escolha do método de pagamento, sendo influenciada por aspetos sociais, psicológicos e contextuais. Os dados analisados confirmam essa ideia: os adultos representam a maior parte dos clientes e também geram a maior receita, seguidos pelos jovens adultos e, por fim, pelos seniores. Além disso, os adultos são os que mais utilizam todos os tipos de pagamento, o que pode estar relacionado com a sua maior presença na amostra e também com o facto de estarem mais familiarizados com diferentes métodos de pagamento. Apesar de Moriuchi (2021) e Kubiczek (2022) apontarem para uma crescente adoção de pagamentos digitais por parte dos consumidores mais jovens, principalmente após a pandemia, os dados mostram um padrão diferente. Como se vê no gráfico “Métodos de Pagamento por Faixa Etária”, presente no *dashboard* 2- Pagamentos & Sazonalidade, os adultos continuam a ser os principais utilizadores mesmo nas opções digitais como *PayPal* e *Venmo*. Isso pode indicar que o uso de pagamentos digitais já não se restringe apenas às faixas etárias mais jovens.

Quanto ao método de envio, a literatura sugere que, embora a rapidez na entrega possa melhorar a experiência do cliente e incentivar compras repetidas, o seu impacto pode ser menos relevante do que fatores como o preço ou as características do produto (Faganel et al., 2024; Davidaviciene et al., 2021). De acordo com os dados analisados, não se observa uma preferência clara entre os diferentes tipos de envio, o que reforça a ideia de que, apesar de importante, o tempo de entrega não é o principal critério na decisão de compra.

Em resumo, os dados empíricos apresentados nos *dashboards* confirmam várias das ideias discutidas na literatura científica. As variáveis género, localização e idade apresentam ligações evidentes com os padrões de compra, escolha de produtos e métodos de pagamento (Abdel Wahab et al., 2023). Esta análise integrada não só valida teorias já conhecidas, mas também oferece *insights* úteis para definir estratégias de *marketing*, segmentar clientes e melhorar os processos logísticos, contribuindo para uma gestão mais personalizada e eficaz da relação com o consumidor.

O objetivo deste estudo foi explorar a ligação entre BI, o comportamento do consumidor e o apoio à tomada de decisão, num ambiente empresarial cada vez mais orientado por dados. Através da revisão sistemática da literatura, seguindo o protocolo PRISMA 2020, foi possível identificar as principais abordagens teóricas e práticas que sustentam esta relação, destacando-se a aplicação concreta de ferramentas como o *Power BI*.

A realização deste estudo foi uma oportunidade para consolidar conhecimentos sobre BI e compreender, de forma prática, como a análise de dados pode sustentar decisões empresariais mais informadas.

Este documento destaca-se por combinar de forma clara áreas fundamentais: o comportamento do consumidor, o BI e a tomada de decisão. Ao integrar estas dimensões, diferencia-se de outras abordagens que tratam estes temas separadamente ou de forma superficial. A construção de *dashboards* interativos permitiu visualizar padrões de consumo, segmentações demográficas, variações sazonais e fatores que influenciam a receita, mostrando como o BI pode transformar dados em *insights* acionáveis.

Além disso, o estudo integrou teorias específicas de comportamento do consumidor, como a Teoria da Identidade Social, da Categorização Social e das Fundações Morais, que ajudaram a situar a análise no meio digital. A investigação também evidenciou como a era digital tem alterado a relação entre consumidores e empresas, reforçando a importância de uma adaptação estratégica por parte das organizações, baseada em dados e análises preditivas.

Esta dissertação ajudou a perceber, de forma prática, como o BI pode contribuir para conhecer melhor o consumidor e apoiar decisões mais conscientes.

8.4 Limitações

Durante o desenvolvimento deste estudo, surgiram algumas limitações que influenciaram a profundidade da análise realizada.

A principal dificuldade prendeu-se com a inexistência de bases de dados públicas específicas sobre *marketing* de vendas, o que exigiu uma pesquisa extensa para encontrar um conjunto de dados adequado. Embora o conjunto de dados utilizado tenha permitido explorar várias dimensões do comportamento do consumidor, a sua origem genérica e não contextualizada numa organização real limitou a aplicabilidade direta dos resultados.

Sendo um conjunto de dados sintético, os resultados obtidos têm um carácter ilustrativo e deverão ser validados futuramente com dados reais de uma organização.

Outra limitação foi a impossibilidade de validar os *dashboards* com utilizadores reais ou com equipas de *marketing*. Esta validação teria permitido perceber melhor a utilidade prática das visualizações e dos KPIs definidos, bem como ajustar os painéis às necessidades dos utilizadores finais.

A ausência de dados transacionais em tempo real também impediu a exploração de funcionalidades mais avançadas do *Power BI*, como alertas dinâmicos ou previsões automatizadas.

Por fim, embora a revisão sistemática tenha seguido o protocolo PRISMA, a exclusão de alguns termos amplos como “*big data*” pode ter limitado o alcance de estudos complementares que poderiam enriquecer a análise teórica.

8.5 Propostas para Trabalhos Futuros

Com base na experiência adquirida ao longo desta dissertação, torna-se pertinente apontar algumas direções que poderão enriquecer futuras investigações nesta área.

Para investigações futuras, seria interessante desenvolver um caso de estudo com dados reais de uma empresa cujo modelo de negócio esteja diretamente ligado ao *marketing* e às vendas. Esta abordagem permitiria criar um sistema de BI mais completo, com *dashboards* adaptados às necessidades específicas da organização e validados por quem os vai utilizar no dia a dia.

Outra possibilidade, seria aprofundar a ligação entre BI e *Big Data*, explorando técnicas de *Machine Learning* para prever comportamentos de compra e personalizar ofertas em tempo real. A inclusão de dados vindos de redes sociais e plataformas de *e-commerce* poderia tornar a análise mais rica e permitir uma segmentação mais precisa dos consumidores.

Por fim, seria interessante explorar a aplicação de BI em contextos específicos como o retalho, a saúde ou os serviços financeiros, avaliando como diferentes setores podem beneficiar da análise do comportamento do consumidor para melhorar a sua performance e competitividade.

REFERÊNCIAS BIBLIOGRÁFICAS

- Abdel Wahab, H., Diao, N. M., & Ahmed Nagaty, S. (2023). Demographic characteristics and consumer decision-making styles: Do they impact fashion product involvement? *Cogent Business and Management*, 10(2). <https://doi.org/10.1080/23311975.2023.2208430>
- Adegoke, J. (2023, April 17). *A Beginner's Guide to Kaggle for Data Science*. <https://www.makeuseof.com/beginners-guide-to-kaggle/>
- Agag, G., Shehawy, Y. M., Almoraish, A., Eid, R., Chaib Lababdi, H., Gherissi Labben, T., & Abdo, S. S. (2024). Understanding the relationship between marketing analytics, customer agility, and customer satisfaction: A longitudinal perspective. *Journal of Retailing and Consumer Services*, 77. <https://doi.org/10.1016/j.jretconser.2023.103663>
- Alawadh, M., & Barnawi, A. (2024). A Consumer Behavior Analysis Framework toward Improving Market Performance Indicators: Saudi's Retail Sector as a Case Study. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(1), 152–171. <https://doi.org/10.3390/jtaer19010009>
- Antal, R., Marasová, D., Hájiček, R., Klapko, P., & Mitrik, V. (2022). Implementation of business intelligence system to analyze the data for mining mechanization – case study. *Acta Montanistica Slovaca*, 27(3), 744–753. <https://doi.org/10.46544/AMS.v27i3.14>
- Awan, U., Shamim, S., Khan, Z., Zia, N. U., Shariq, S. M., & Khan, M. N. (2021). Big data analytics capability and decision-making: The role of data-driven insight on circular economy performance. *Technological Forecasting and Social Change*, 168. <https://doi.org/10.1016/j.techfore.2021.120766>
- Bañka, M., Daniłowski, J., Czerliński, M., Murawski, J., Żochowska, R., & Sobota, A. (2022). A Feedback Analysis Automation Using Business Intelligence Technology in Companies Organizing Urban Public Transport. *Sustainability (Switzerland)*, 14(18). <https://doi.org/10.3390/su141811740>
- Basu, R., Lim, W. M., Kumar, A., & Kumar, S. (2023). Marketing analytics: The bridge between customer psychology and marketing decision-making. In *Psychology and Marketing* (Vol. 40, Issue 12, pp. 2588–2611). John Wiley and Sons Inc. <https://doi.org/10.1002/mar.21908>

- Bokrantz, J., Subramaniyan, M., & Skoogh, A. (2023). Realising the promises of artificial intelligence in manufacturing by enhancing CRISP-DM. *Production Planning and Control*. <https://doi.org/10.1080/09537287.2023.2234882>
- Brewis, C., Dibb, S., & Meadows, M. (2023). Leveraging big data for strategic marketing: A dynamic capabilities model for incumbent firms. *Technological Forecasting and Social Change*, *190*. <https://doi.org/10.1016/j.techfore.2023.122402>
- Cadden, T., Weerawardena, J., Cao, G., Duan, Y., & McIvor, R. (2023). Examining the role of big data and marketing analytics in SMEs innovation and competitive advantage: A knowledge integration perspective. *Journal of Business Research*, *168*. <https://doi.org/10.1016/j.jbusres.2023.114225>
- Castillo, V. A. S., & Del Río, J. A. J. (2023). Consumer Behavior and Factors that Influence Consumption and Customer Satisfaction. *TEM Journal*, *12*(2), 820–831. <https://doi.org/10.18421/TEM122-27>
- Chatterjee, S., Chaudhuri, R., Gupta, S., Sivarajah, U., & Bag, S. (2023). Assessing the impact of big data analytics on decision-making processes, forecasting, and performance of a firm. *Technological Forecasting and Social Change*, *196*. <https://doi.org/10.1016/j.techfore.2023.122824>
- Chen, H., Chiang, R. H. L., & Storey, V. C. (2012). Business intelligence and analytics: From big data to big impact. *MIS Quarterly: Management Information Systems*, *36*(4), 1165–1188. <https://doi.org/10.2307/41703503>
- Corboş, R. A., Bunea, O. I., & Triculescu, S. M. (2023). Towards Sustainable Consumption: Consumer Behavior and Market Segmentation in the Second-Hand Clothing Industry. *Amfiteatru Economic*, *25*(Special Issue 17), 1064–1080. <https://doi.org/10.24818/EA/2023/S17/1064>
- Dehnert, M., & Schumann, J. (2022). Uncovering the digitalization impact on consumer decision-making for checking accounts in banking. *Electronic Markets*, *32*(3), 1503–1528. <https://doi.org/10.1007/s12525-022-00524-4>
- Elkabalawy, M., Al-Sakkaf, A., Mohammed Abdelkader, E., & Alfalah, G. (2024). CRISP-DM-Based Data-Driven Approach for Building Energy Prediction Utilizing Indoor and Environmental Factors. *Sustainability*, *16*(17), 7249. <https://doi.org/10.3390/su16177249>

- Faganel, A., Pačarić, F., & Rižnar, I. (2024). The Impact of Gamification on Slovenian Consumers' Online Shopping. *Administrative Sciences*, 14(5). <https://doi.org/10.3390/admsci14050086>
- Fekete-Farkas, M., Gholampour, A., Bouzari, P., Jarghooiyan, H., & Ebrahimi, P. (2021). How gender and age can affect consumer purchase behavior? Evidence from A microeconomic perspective from Hungary. *AD-Minister*, 39, 25–46. <https://doi.org/10.17230/Ad-minister.39.2>
- Giannakopoulos, N. T., Terzi, M. C., Sakas, D. P., Kanellos, N., Toudas, K. S., & Migkos, S. P. (2024). Agroeconomic Indexes and Big Data: Digital Marketing Analytics Implications for Enhanced Decision Making with Artificial Intelligence-Based Modeling. *Information (Switzerland)*, 15(2). <https://doi.org/10.3390/info15020067>
- Goenka, S., & Thomas, M. (2024). Moral foundations theory and consumer behavior. *Journal of Consumer Psychology*, 34(3), 536–540. <https://doi.org/10.1002/jcpy.1429>
- Gonçalves, C. T., Gonçalves, M. J. A., & Campante, M. I. (2023). Developing Integrated Performance Dashboards Visualisations Using Power BI as a Platform. *Information (Switzerland)*, 14(11). <https://doi.org/10.3390/info14110614>
- Gonçalves, M., Salgado, C., de Sousa, A., & Teixeira, L. (2025). Data Storytelling and Decision-Making in Seaport Operations: A New Approach Based on Business Intelligence. *Sustainability (Switzerland)*, 17(1). <https://doi.org/10.3390/su17010337>
- Gordon R, F., Jorge M, O. C., & Rafael B, P. (2021). Consumer behavior analysis and the marketing firm: measures of performance. *Journal of Organizational Behavior Management*, 41(2), 97–123. <https://doi.org/10.1080/01608061.2020.1860860>
- Guo, S., & Zhai, R. (2022). E-Commerce Precision Marketing and Consumer Behavior Models Based on IoT Clustering Algorithm. *Journal of Cases on Information Technology*, 24(5). <https://doi.org/10.4018/JCIT.302244>
- Gurcan, F., Ayaz, A., Menekse Dalveren, G. G., & Derawi, M. (2023). Business Intelligence Strategies, Best Practices, and Latest Trends: Analysis of Scientometric Data from 2003 to 2023 Using Machine Learning. *Sustainability (Switzerland)*, 15(13). <https://doi.org/10.3390/su15139854>

- Kimball, R., & Ross, M. (2002). *The Data Warehouse Toolkit* (R. Elliott, Ed.).
- Kohara Melchior, L. A., Fernandes Brilhante, A., Tomaz da Silva, L. J., & Tomaz da Silva, L. J. (2023). Business Intelligence no apoio à gestão estratégica em saúde: um relato de experiência. *Revista de Epidemiologia e Controle de Infecção*, 12(4). <https://doi.org/10.17058/reci.v12i4.17422>
- Kongthanasuwan, T., Sriwiboon, N., Horbanluekit, B., Laesanklang, W., & Krityakierne, T. (2023). Market Analysis with Business Intelligence System for Marketing Planning. *Information (Switzerland)*, 14(2). <https://doi.org/10.3390/info14020116>
- Kubiczek, J. (2022). Effects of COVID-19 on payment method preferences of Poles. *Financial Internet Quarterly*, 18(4), 35–49. <https://doi.org/10.2478/fiqf-2022-0026>
- Kunc, J., Novotná, M., Reichel, V., Križan, F., & Bilková, K. (2024). Bricks or clicks? Factors influencing shopping behavior of Generation Z. *Equilibrium. Quarterly Journal of Economics and Economic Policy*, 19(2), 521–548. <https://doi.org/10.24136/eq.2999>
- Lebkiri, N., Daoudi, M., Abidli, Z., Elturk, J., Soulaymani, A., Khatori, Y., El Madhi, Y., & Benattou, M. (2021). Using Machine Learning for Prediction Students Failure in Morocco: an Application of the CRISP-DM Methodology. *International Journal of Education and Information Technologies*, 15, 344–352. <https://doi.org/10.46300/9109.2021.15.36>
- Liashenko, O., Kravets, T., & Prokopenko, M. (2021). Consumer Behavior Clustering of Food Retail Chains by Machine Learning Algorithms. *ACCESS Journal: Access to Science, Business, Innovation in Digital Economy*, 234–251. [https://doi.org/10.46656/access.2021.2.3\(3\)](https://doi.org/10.46656/access.2021.2.3(3))
- Liberati, A., Altman, D. G., Tetzlaff, J., Mulrow, C., Gøtzsche, P. C., Ioannidis, J. P. A., Clarke, M., Devereaux, P. J., Kleijnen, J., & Moher, D. (2009). The PRISMA statement for reporting systematic reviews and meta-analyses of studies that evaluate health care interventions: explanation and elaboration. *Journal of Clinical Epidemiology*, 62(10), e1–e34. <https://doi.org/10.1016/j.jclinepi.2009.06.006>
- Luhn, H. P. (1958). A Business Intelligence System. *IBM JOURNAL OF RESEARCH AND DEVELOPMENT*, 2(4), 314–319.

- Lundén, N., Bekar, E. T., Skoogh, A., & Bokrantz, J. (2023). Domain Knowledge in CRISP-DM: An Application Case in Manufacturing. *IFAC-PapersOnLine*, *56*(2), 7603–7608. <https://doi.org/10.1016/j.ifacol.2023.10.1156>
- Martinez-Plumed, F., Contreras-Ochando, L., Ferri, C., Hernandez-Orallo, J., Kull, M., Lachiche, N., Ramirez-Quintana, M. J., & Flach, P. (2021). CRISP-DM Twenty Years Later: From Data Mining Processes to Data Science Trajectories. *IEEE Transactions on Knowledge and Data Engineering*, *33*(8), 3048–3061. <https://doi.org/10.1109/TKDE.2019.2962680>
- Moriuchi, E. (2021). An empirical study of consumers' intention to use biometric facial recognition as a payment method. *Psychology and Marketing*, *38*(10), 1741–1765. <https://doi.org/10.1002/mar.21495>
- Mositsa, R. J., Van der Poll, J. A., & Dongmo, C. (2023). Towards a Conceptual Framework for Data Management in Business Intelligence. *Information (Switzerland)*, *14*(10). <https://doi.org/10.3390/info14100547>
- Necochea-Chamorro, J. I., & Larrea-Goycochea, L. (2023a). Business Intelligence Applied in the Corporate Sector: A Systematic Review. *TEM Journal*, *12*(4), 2225–2234. <https://doi.org/10.18421/TEM124-33>
- Necochea-Chamorro, J. I., & Larrea-Goycochea, L. (2023b). Business Intelligence Applied in the Corporate Sector: A Systematic Review. *TEM Journal*, *12*(4), 2225–2234. <https://doi.org/10.18421/TEM124-33>
- Niu, Y., Ying, L., Yang, J., Bao, M., & Sivaparthipan, C. B. (2021). Organizational Business Intelligence and Decision Making Using Big Data Analytics. *Information Processing and Management*, *58*(6). <https://doi.org/10.1016/j.ipm.2021.102725>
- Page, M. J., McKenzie, J. E., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J., Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., McDonald, S., ... Moher, D. (2021). The PRISMA 2020 statement: An updated guideline for reporting systematic reviews. *Journal of Clinical Epidemiology*, *134*, 178–189. <https://doi.org/10.1016/j.jclinepi.2021.03.001>
- Page, M. J., Moher, D., Bossuyt, P. M., Boutron, I., Hoffmann, T. C., Mulrow, C. D., Shamseer, L., Tetzlaff, J. M., Akl, E. A., Brennan, S. E., Chou, R., Glanville, J.,

- Grimshaw, J. M., Hróbjartsson, A., Lalu, M. M., Li, T., Loder, E. W., Mayo-Wilson, E., Mcdonald, S., ... Mckenzie, J. E. (2021). PRISMA 2020 explanation and elaboration: Updated guidance and exemplars for reporting systematic reviews. In *The BMJ* (Vol. 372). BMJ Publishing Group. <https://doi.org/10.1136/bmj.n160>
- Pancić, M., Čučić, D., & Serdarušić, H. (2023). Business Intelligence (BI) in Firm Performance: Role of Big Data Analytics and Blockchain Technology. *Economies*, *11*(3). <https://doi.org/10.3390/economies11030099>
- Picozzi, P., Nocco, U., Pezzillo, A., De Cosmo, A., & Cimolin, V. (2024). The Use of Business Intelligence Software to Monitor Key Performance Indicators (KPIs) for the Evaluation of a Computerized Maintenance Management System (CMMS). *Electronics (Switzerland)*, *13*(12). <https://doi.org/10.3390/electronics13122286>
- Pinkovetskaia, Y. S., Lebedev, A. V., & Somkin, A. A. (2022). Regional Differences of Digitalization Level in the Activities of Organizations in Russia. *REGIONOLOGY*, *30*(3), 721–747. <https://doi.org/10.15507/2413-1407.120.030.202203.721-747>
- Prevedello, L. M., Andriole, K. P., & Khorasani, R. (2008). Business Intelligence Tools and Performance Improvement in Your Practice. *Journal of the American College of Radiology*, *5*(12), 1210–1211. <https://doi.org/10.1016/j.jacr.2008.08.018>
- Proença, M., & Martins, T. S. (2023). The role of absorptive capacity in the use of digital marketing analytics for effective marketing decisions. *Journal of Marketing Analytics*. <https://doi.org/10.1057/s41270-023-00224-8>
- Sanabia-Lizarraga, K. G., Carballo-Mendivil, B., Arellano-González, A., & Bueno-Solano, A. (2024). Business Intelligence for Agricultural Foreign Trade: Design and Application of Power BI Dashboard. *Sustainability (Switzerland)*, *16*(21). <https://doi.org/10.3390/su16219576>
- Schröer, C., Kruse, F., & Gómez, J. M. (2021). A systematic literature review on applying CRISP-DM process model. *Procedia Computer Science*, *181*, 526–534. <https://doi.org/10.1016/j.procs.2021.01.199>
- Shwawreh, S., & Awamleh, F. T. (2025). Marketing intelligence in digital age: How business intelligence tools drive e-marketing strategies. *Journal of Project Management (Canada)*, *10*(2), 372–382. <https://doi.org/10.5267/j.jpmp.2025.1.002>

- Sousa, R., Miranda, R., Moreira, A., Alves, C., Lori, N., & Machado, J. (2021). Software tools for conducting real-time information processing and visualization in industry: An up-to-date review. In *Applied Sciences (Switzerland)* (Vol. 11, Issue 11). MDPI AG. <https://doi.org/10.3390/app11114800>
- Sukopová, D., Kádárová, J., Vyrostková, L., & Lachvajderová, L. (2023). Business Intelligence and its Development From the Perspective of Publication in Scientific Journals. *Acta Mechanica Slovaca*, 27(4), 52–61. <https://doi.org/10.21496/ams.2023.038>
- Taghikhah, F., Voinov, A., Shukla, N., & Filatova, T. (2021). Shifts in consumer behavior towards organic products: Theory-driven data analytics. *Journal of Retailing and Consumer Services*, 61. <https://doi.org/10.1016/j.jretconser.2021.102516>
- Watson, H. J., & Wixom, B. H. (2007). The Current State of Business Intelligence. *Computer*, 40(9), 96–99. <https://doi.org/10.1109/MC.2007.331>
- White, K., Wang, W., & Aquino, K. (2024). Collective consciousness and consumer behavior. *Journal of Consumer Psychology*. <https://doi.org/10.1002/jcpy.1433>
- Wlodarczyk, K. (2021). Trends of Evolution in Consumer Behavior in the Contemporary World. *Management Issues*, 19(1), 39–51. <https://doi.org/10.7172/1644-9584.91.x>
- Xu, A., Li, Y., & Donta, P. K. (2024). Marketing Decision Model and Consumer Behavior Prediction With Deep Learning. *Journal of Organizational and End User Computing*, 36(1). <https://doi.org/10.4018/JOEUC.336547>
- Zhang, Y., Wang, A., & Hu, W. (2023). Deep Learning-Based Consumer Behavior Analysis and Application Research. *Wireless Communications and Mobile Computing*, 2023, 1–1. <https://doi.org/10.1155/2023/9874213>
- Zwart, P. de. (2022). Inequality in late colonial Indonesia: new evidence on regional differences. *Cliometrica*, 16(1), 175–211. <https://doi.org/10.1007/s11698-020-00220-3>