



**Análise de dados na compreensão do
comportamento de compra *online*: Caso de estudo
na La Redoute Portugal**

Mestrado em Gestão

Hugo Abbott Barreiros

Leiria, fevereiro de 2025



Análise de dados na compreensão do comportamento de compra *online*: Caso de estudo na La Redoute Portugal

Mestrado em Gestão

Hugo Abbott Barreiros

Relatório de estágio realizado sob a orientação da Professora Doutora Iolanda Sofia dos Santos Bernardino, sob supervisão da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria

Leiria, fevereiro de 2025

Originalidade e Direitos de Autor

O presente relatório de estágio é original, elaborado unicamente para este fim, tendo sido devidamente citados todos os autores cujos estudos e publicações contribuíram para o elaborar.

Reproduções parciais deste documento serão autorizadas na condição de que seja mencionado o Autor e feita referência ao ciclo de estudos no âmbito do qual o mesmo foi realizado, a saber, Curso de Mestrado em Gestão, no ano letivo 2024/2025, da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria, Portugal, e, bem assim, à data das provas públicas que visaram a avaliação destes trabalhos.

Agradecimentos

A realização deste trabalho não teria sido possível sem o apoio e a colaboração de várias pessoas e entidades, às quais gostaria de expressar a minha sincera gratidão.

Em primeiro lugar, quero agradecer à La Redoute Portugal por me ter dado a oportunidade de realizar o meu estágio curricular na empresa. Esta experiência permitiu-me aprofundar os meus conhecimentos e adquirir competências fundamentais para o meu percurso profissional. Trabalhar num ambiente dinâmico e exigente como este foi uma experiência enriquecedora, que me ajudou a crescer tanto a nível académico como pessoal.

Um agradecimento muito especial à Gaëlle Sousa, que me acompanhou durante todo o período de estágio. A sua orientação, paciência e disponibilidade foram essenciais para que eu pudesse aprender e desenvolver as minhas capacidades de forma eficaz. O seu apoio constante e os ensinamentos transmitidos foram determinantes para que esta experiência fosse tão produtiva e enriquecedora.

Não poderia deixar de agradecer à minha Professora Iolanda Bernardino, pelo acompanhamento e pela preciosa ajuda na elaboração deste relatório de estágio. A sua orientação, dedicação e sugestões foram fundamentais para a concretização deste trabalho, permitindo-me estruturar e apresentar as aprendizagens adquiridas de forma clara e objetiva no meu relatório de estágio.

Por fim, quero ainda agradecer a todos os colegas, amigos e familiares que, de alguma forma, me incentivaram e apoiaram ao longo deste percurso. O vosso apoio foi imprescindível para que conseguisse superar os desafios e concluir esta etapa com sucesso.

Resumo

No ambiente competitivo atual, a análise de dados é fundamental para as empresas, pois permite compreender os comportamentos de compra dos consumidores e, assim, tomar decisões estratégicas que impulsionam o crescimento e a eficiência dos negócios. Ao coletar e examinar informações sobre preferências e tendências, as organizações conseguem identificar padrões que otimizam suas estratégias de *marketing* e vendas. Isso permite que as marcas personalizem as suas ofertas e melhorem a experiência do cliente, proporcionando *insights* valiosos sobre o que motiva as decisões de compra.

Além disso, a sazonalidade desempenha um papel importante nessa análise, uma vez que os comportamentos de compra variam ao longo do ano, influenciados por datas comemorativas e eventos especiais. Compreender essas flutuações permite às empresas antecipem a procura, ajustem *stocks* e implementem campanhas de *marketing* eficazes.

O principal objetivo deste estudo é analisar se a integração de dados internos e externos permitem identificar padrões sazonais de consumo em produtos para casa no mercado de *e-commerce*. Para isso, é fundamental reconhecer esses padrões no comportamento dos consumidores, analisando a relação entre os dados recolhidos e verificando a existência de correlação, através da aplicação da correlação de Pearson. Dessa forma, torna-se essencial a criação de um mapa de sazonalidade, que facilite a interpretação dos dados recolhidos e possibilite uma análise mais eficaz de toda a informação processada.

Os resultados deste estudo confirmaram que a integração de dados internos e externos é essencial para identificar padrões sazonais de consumo em produtos para a categoria “casa” no mercado *online*, evidenciando uma correlação entre os dados analisados. Além disso, foi possível observar que diferentes produtos apresentam sazonalidades distintas, exigindo estratégias ajustadas. No entanto, é importante considerar que fatores como ações comerciais, nomeadamente promoções e alterações económicas podem influenciar significativamente esses padrões sazonais.

Palavras-chave: Análise de Dados, Comportamento do Consumidor, *E-Commerce*, Sazonalidade.

Abstract

In today's competitive environment, data analytics is critical for businesses to understand consumer buying patterns and make strategic decisions that drive growth and efficiency. Data analytics is essential for businesses to understand consumer buying patterns. By collecting and studying information about preferences and trends, companies can identify patterns that optimize their marketing and sales strategies. This allows brands to personalize their offerings and improve the customer experience, providing valuable insights into what drives purchase decisions.

Seasonality also plays an important role in this analysis, as buying patterns fluctuate throughout the year, influenced by holidays and special events. Understanding these variations enables companies to anticipate demand, adjust inventory levels and implement effective marketing campaigns.

The main objective of this study is to analyse whether the integration of internal and external data allows the identification of seasonal consumption patterns of household products in the e-commerce market. To achieve this, it is essential to identify these patterns in consumer behavior by analyzing the relationship between the data collected and verifying the existence of a correlation using Pearson's correlation analysis. The creation of a seasonality map is therefore crucial, as it facilitates the interpretation of the data collected and allows a more effective analysis of all the information processed.

The results of this study confirmed that the integration of internal and external data is essential to identify seasonal consumption patterns of household products in the online market, highlighting a correlation between the data analyzed. Different products exhibit distinct seasonal trends, requiring tailored strategies. However, it is important to bear in mind that factors such as commercial actions, in particular promotions, and economic changes can have a significant impact.

Keywords: *Consumer Behavior, Data Analytics, E-commerce, Seasonality.*

Índice

Originalidade e Direitos de Autor	iii
Agradecimentos.....	v
Resumo.....	vi
Abstract.....	vii
1. Introdução.....	1
2. Caracterização da Entidade de Acolhimento	3
2.1. Ficha técnica	3
2.2. História da empresa	3
2.3. Missão, Visão e Valores	4
2.3.1. Missão	4
2.3.2. Visão.....	4
2.3.3. Valores	4
2.4. Atividades da organização.....	5
2.4.1. Organograma da empresa.....	5
2.5. Caracterização dos Clientes	6
2.6. Análise SWOT	7
3. Programa de Estágio	11
3.1. Tarefa 1: Construção de um calendário de sazonalidade.....	12
3.2. Tarefa 2: Mapeamento das categorias produto.....	12
3.3. Tarefa 3: Revisão das tendências de produtos para casa	13
3.4. Tarefa 4: Estudo de questionário realizado pela La Redoute.....	13
3.5. Tarefa 5: <i>Benchmark Pricing</i> de categorias dos móveis relevantes para a atividade da La Redoute Portugal	13

4.	Problema de Investigação	14
4.1.	Revisão da Literatura.....	14
4.1.1.	Comportamento do Consumidor	14
4.1.1.1.	Teorias e Modelos de Comportamento do Consumidor	14
4.1.1.2.	Fatores que influenciam as decisões de compra dos consumidores.....	17
4.1.1.3.	Comportamento de Compra <i>Online</i>	19
4.1.1.3.1.	Fatores Decisivos na Escolha das Compras pelo <i>Online</i>	21
4.1.2.	<i>Data Science</i>	22
4.1.3.	Análise de Dados	22
4.1.3.1.	Qualidade das bases de dados	24
4.1.3.2.	Qualidade da tomada de decisão	25
4.1.3.3.	O impacto da análise de dados na tomada de decisão.....	27
4.1.4.	Papel da sazonalidade no <i>e-commerce</i>	29
4.1.4.1.	A importância da Análise de Dados na identificação de padrões sazonais.....	30
4.1.4.2.	Ferramentas de Análise de Dados para identificar sazonalidade.....	31
4.1.4.2.1.	<i>Google Trends</i> como ferramenta de estudo das tendências sazonais..	32
4.2.	Metodologia.....	33
4.2.1.	Hipótese	34
4.2.2.	Amostra e recolha de dados.....	35
4.2.3.	<i>Knowledge Discovery in Databases</i> (KDD).....	36
4.2.3.1.	Conceito	38
4.2.3.2.	<i>Data Mining</i>	39
4.2.3.3.	Variáveis	40
4.2.3.4.	Procedimento.....	45
4.2.3.4.1.	Compreensão do Domínio da Aplicação.....	45
4.2.3.4.2.	Seleção dos Dados.....	46
4.2.3.4.3.	Limpeza e Pré-processamento dos Dados.....	47
4.2.3.4.4.	Transformação dos Dados.....	48
4.2.3.4.5.	<i>Data Mining</i>	49
4.2.3.4.6.	Avaliação e Interpretação dos Resultados.....	51
4.2.3.4.7.	Aplicação do Conhecimento Descoberto	52

4.3. Resultados	53
4.4. Discussão	67
5. Conclusão	71
Referências Bibliográficas.....	73
Anexos	86

Lista de Figuras

Figura 1 - Produtos vendidos pela La Redoute Portugal	5
Figura 2 - Clientes da La Redoute Portugal	7
Figura 3 - Visão geral dos passos de processo do KDD.....	38
Figura 4 - Mapa de Sazonalidade (Sofás).....	54
Figura 5 - Mapa de Sazonalidade (Mobiliário de Casa de Banho).....	55
Figura 6 - Mapa de Sazonalidade (Arrumação)	56
Figura 7 - Mapa de Sazonalidade (Consola/Mesa de Apoio).....	56
Figura 8 - Mapa de Sazonalidade (Espelho).....	57
Figura 9 - Mapa de Sazonalidade (Decoração)	57
Figura 10 - Mapa de Sazonalidade (Decoração de mesa).....	58
Figura 11 - Mapa de Sazonalidade (Decoração Têxtil).....	59
Figura 12 - Mapa de Sazonalidade (Iluminação)	59
Figura 13 - Mapa de Sazonalidade (Janelas).....	60
Figura 14 - Mapa de Sazonalidade (Jardim).....	60
Figura 15 - Mapa de Sazonalidade (<i>Literie</i>).....	61
Figura 16 - Mapa de Sazonalidade (Mesa/Cadeira)	61
Figura 17 - Mapa de Sazonalidade (Mobiliário de Cozinha)	62
Figura 18 - Mapa de Sazonalidade (Mobiliário de Escritório).....	62
Figura 19 - Mapa de Sazonalidade (Mobiliário Principal).....	63
Figura 20 - Mapa de Sazonalidade (Quarto)	63
Figura 21 - Mapa de Sazonalidade (Roupa de Cama).....	64
Figura 22 - Mapa de Sazonalidade (Roupa de Cozinha).....	64
Figura 23 - Mapa de Sazonalidade (Tapetes).....	65
Figura 24 - Mapa de Sazonalidade (Têxtil de Banho).....	65
Figura 25 - Mapa de Sazonalidade (Toalha de Praia)	65
Figura 26 - Mapa de Sazonalidade (Toalha de Banho e Roupão).....	65
Figura 27 - Mapa de Sazonalidade (Têxtil de Mesa).....	66

Lista de tabelas

Tabela 1 - Análise SWOT - La Redoute Portugal.....	8
Tabela 2 - Plano de Trabalho do estágio na La Redoute Portugal	11
Tabela 3 - Capacidades da Análise de dados: Fatores e Variáveis	23
Tabela 4 - Qualidades das bases de dados: Fatores e Variáveis.....	24
Tabela 5 - Fatores que influenciam a qualidade da tomada de decisão	26
Tabela 6 - Correlação de Pearson da família dos Sofás	55
Tabela 7 - Correlação de Pearson da família do Mobiliário de Casa de Banho.....	56
Tabela 8 - Correlação de Pearson da família de Arrumação.....	56
Tabela 9 - Correlação de Pearson da família de Consola/Mesa de Apoio	57
Tabela 10 - Correlação de Pearson da família de Decoração e do produto Espelho.....	58
Tabela 11 - Correlação de Pearson da família de Decoração de Mesa	58
Tabela 12 - Correlação de Pearson da família de Decoração Têxtil	59
Tabela 13 - Correlação de Pearson da família de Iluminação.....	59
Tabela 14 - Correlação de Pearson da família das Janelas.....	60
Tabela 15 - Correlação de Pearson da família do Jardim.....	60
Tabela 16 - Correlação de Pearson da família da <i>Literie</i>	61
Tabela 17 - Correlação de Pearson da família das Mesas e Cadeiras	61
Tabela 18 - Correlação de Pearson da família do Mobiliário de Cozinha.....	62
Tabela 19 - Correlação de Pearson da família do Mobiliário de Escritório	62
Tabela 20 - Correlação de Pearson da família do Mobiliário Principal	63
Tabela 21 - Correlação de Pearson da família do Quarto	63
Tabela 22 - Correlação de Pearson da família da Roupa de Cama	64
Tabela 23 - Correlação de Pearson da família da Roupa de Cozinha	64
Tabela 24 - Correlação de Pearson da família dos Tapetes.....	65
Tabela 25 - Correlação de Pearson da família de Têxtil de Banho	66
Tabela 26 - Correlação de Pearson da família de Têxtil de Mesa.....	66
Tabela 27 - Escala do Coeficiente de Pearson das famílias de produtos para casa.....	68
Tabela 28 - Correlação de Pearson de todas as famílias de produtos.....	68

Lista de siglas e acrónimos

ARIMA	<i>Autoregressive Integrated Moving Average</i>
DUNS	<i>Data Universal Numbering System</i>
EKB	<i>Engel-Kollat-Blackwell</i>
ESTG	Escola Superior de Tecnologia e Gestão
KDD	<i>Knowledge Discovery in Databases</i>
LSTM	<i>Long Short-Term Memory</i>
MAPE	<i>Mean Absolute Percentage Error</i>
NIPC	Número de Identificação de Pessoa Coletiva
OLAP	<i>Online Analytical Processing</i>
RFID	<i>Radio Frequency Identification</i>
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
STL	<i>Seasonal-Trend Decomposition using Loess</i>

1. Introdução

O presente relatório enquadra-se no âmbito do estágio curricular relativo ao 2º ano do Mestrado em Gestão da Escola Superior de Tecnologia e Gestão do Instituto Politécnico de Leiria. O estágio decorreu na empresa La Redoute Portugal – Vendas à distância S.A., localizada na zona industrial da Barosa, em Leiria, Portugal. A La Redoute Portugal tem como principal atividade do comércio a retalho por correspondência ou pela *Internet*, sendo umas das empresas de *e-commerce* mais antigas em Portugal.

O estágio teve a duração de quatro meses compreendidos, 80 dias, 670 horas, entre setembro de 2024 e janeiro de 2025, decorrendo dentro do departamento do produto, *e-store*, da empresa. O trabalho é composto por quatro partes, começando com uma apresentação da empresa onde foi realizado o estágio. De seguida, são descritas as tarefas desenvolvidas durante o período de estágio. Posteriormente, aborda-se o problema de investigação, incluindo a revisão da literatura, a metodologia proposta para a resolução do problema e os resultados obtidos com o estudo. Por fim, apresenta-se uma conclusão, que inclui tanto uma reflexão sobre a realização do estágio como uma conclusão relativa ao problema de investigação.

Durante este período, o estágio centrou-se sobretudo no desenvolvimento de um mapa de sazonalidade para os produtos de casa, uma vez que não existia um mapa específico que indicasse o melhor período para impulsionar uma determinada categoria de produtos. Além disso, foram realizadas outras tarefas, como o mapeamento das categorias de produtos de casa em termos de quantidades e rotatividade, comparando esses dados com os apresentados pela La Redoute França, a identificação de tendências no mercado em categorias específicas de produtos, a análise das respostas a um inquérito realizado pela empresa, e o estudo comparativo dos preços da La Redoute Portugal em relação aos principais concorrentes no mercado de produtos para o lar.

Estas tarefas permitiram-me adquirir uma melhor compreensão do tipo de atividades desenvolvidas por este departamento, ampliando os meus conhecimentos em análise de dados e estratégias de mercado.

Aprendi a identificar padrões sazonais e tendências, reforçando as minhas competências em posicionamento estratégico e contribuindo para decisões mais informadas e alinhadas com as necessidades da empresa. Adicionalmente, estas atividades ajudaram-me a entender melhor as perceções que os clientes podem ter sobre uma marca e os aspetos mais valorizados por estes.

A partir sobretudo da tarefa principal, a construção de um mapa de sazonalidade para os produtos de casa, o objetivo do trabalho passava por responder à seguinte questão "Como é que a análise de dados internos e externos contribui para a compreensão do comportamento de compra e identificação de tendências sazonais de consumo de produtos para casa (mobiliário e têxtil-lar) no mercado de *e-commerce*?". Uma vez que o objetivo passava por criar uma ferramenta que apoiasse a empresa em diversos aspetos comerciais, como identificar o melhor período para destacar determinadas categorias de produtos, pois, na categoria de produtos para casa, é mais complexo perceber a sazonalidade dos seus produtos e, para além disso, atualmente ainda existem poucos estudos sobre o tema, havendo muitas possibilidades de estudo sobre este.

Assim, a questão de investigação do estudo teve como base as seguintes hipóteses:

H0: A combinação de dados internos e externos permite identificar padrões sazonais de consumo em produtos para casa no mercado de e-commerce, facilitando o desenvolvimento das estratégias de marketing da empresa.

H1: A integração dos dados internos e externos não é eficaz na identificação de padrões sazonais de consumo em produtos para casa no mercado de e-commerce.

Para estudar a resolução das hipóteses, o método de estudo utilizado foi o processo de *Knowledge Discovery in Databases* (KDD), em que se baseia na descoberta de conhecimento em bases de dados, isto é, foca-se na extração de padrões úteis e compreensíveis para apoiar nas tomadas de decisão.

2. Caracterização da Entidade de Acolhimento

2.1. Ficha técnica

A entidade de acolhimento do estágio tem o nome de La Redoute Portugal – Vendas à distância S.A., é uma Sociedade Anónima que se dedica ao comércio a retalho por correspondência ou pela *Internet* (CAE 47910), na qual esta está integrada em vários setores de atividade como é o caso do vestuário, calçado, têxtil-lar, mobiliário, eletrodomésticos e bem-estar. O NIPC é 501213031, sendo o seu código do *Data Universal Numbering System* (DUNS) o 450705033. A sede está localizada no distrito de Leiria, na Zona Industrial da Barosa, Rua Beco dos Petigais, Fração F, números 45 e 65.

2.2. História da empresa

A história da La Redoute começa no ano de 1837 na cidade de Roubaix, no norte da França, tendo esta sido fundada por Joseph Pollet, um empresário francês. Inicialmente a empresa operava como uma fábrica têxtil, esta em 1928 decidiu iniciar a sua própria atividade de vendas por correspondência, lançando o seu primeiro catálogo de moda (Redoute, 2024). Nos anos 90, com o aparecimento da *Internet*, a empresa modernizou-se, tendo criado o seu *website* de comércio eletrónico, expandindo ainda mais a marca (Redoute, 2024).

Em Portugal, a La Redoute surge no ano de 1988, com um modelo de negócios baseado na venda por catálogo, onde a mesma se conseguia destacar no país pela oferta de moda feminina, masculina e infantil, bem como por produtos para a casa, como têxteis e decoração (Redoute, 2018). Com o advento da *Internet* e o crescimento das vendas *online*, a La Redoute foi uma das pioneiras em Portugal a adaptar o seu modelo de negócios ao comércio eletrónico. A transição para o *e-commerce* foi gradual, mas sólida, culminando na criação de uma loja *online* que, atualmente, é o principal canal de vendas da empresa (Têxtil, 2006).

Hoje, a La Redoute em Portugal é vista como uma referência em moda e decoração, com uma forte presença digital e um compromisso com a qualidade e a satisfação do cliente. A empresa continua a expandir a sua oferta de produtos, mantendo-se fiel à sua herança de quase quatro décadas de atuação no país (Marketeer, 2022).

2.3. Missão, Visão e Valores

2.3.1. Missão

Tal como refere Drucker (1973), a missão vai ser a base de toda a estratégia organizacional, sendo esta centrada no cliente. Com isso, a missão deve ser capaz de definir a razão de ser da organização em termos do valor que proporciona ao cliente, não se focando apenas nos produtos e serviços que oferece (Drucker, 1973).

É com essa mentalidade que a missão da La Redoute Portugal foi criada, ou seja, a marca procura acompanhar as famílias em todas as fases das suas vidas, contribuindo para tornar a vida mais bela e o mundo um lugar melhor. Daí, a missão da La Redoute Portugal ser **“Abrimos portas a todas as famílias, de todos lugares! Um convite para experimentar o lado bom da vida”** (La Redoute Portugal, 2024).

2.3.2. Visão

A visão de uma organização deve ser uma imagem clara e inspiradora do futuro daquilo que deseja criar, sendo esta partilhada por todos na organização, funcionando como uma força motivadora que guia o comportamento e as decisões estratégicas (Senge, 1990).

A La Redoute Portugal tem como visão **“(…) Tornando o estilo francês acessível a todos, valorizando a importância da família (...)”** (La Redoute Portugal, 2024). Assim, a empresa procura destacar-se como referência no setor da moda e decoração, oferecendo produtos de qualidade, com estilo e sustentáveis, enquanto promove a inclusão e a diversidade.

2.3.3. Valores

Os valores numa organização são crenças fundamentais que orientam o comportamento e as decisões dentro de uma organização, sendo estes um dos pilares centrais da cultura organizacional (Schein, 2010). Os mesmos vão refletir o que é considerado importante pela organização e pelos seus membros, moldando a forma como estes interagem, tomam decisões e resolvem problemas (Schein, 2010).

Deste modo, a La Redoute Portugal considera que os principais pilares da sua cultura passam por (La Redoute Portugal, 2024):

- **Ambição:** O espírito empreendedor no seio da La Redoute incentiva a perseverança. Tornar esse tipo de cultura possível requer uma energia pragmática que estimula a capacidade de mobilizar equipas, levando-as a objetivos ambiciosos.
- **Criação:** Na La Redoute, a criatividade e inovação cruzam-se no ponto crucial de uma delicada equação: reinventar continuamente coleções e manter o olhar firme no futuro; e fazer isso enquanto mantém o compromisso de continuar a respirar uma nova vida num estilo contemporâneo e sempre acessível.
- **Alto padrão de excelência:** Na La Redoute, a busca pela excelência é o que impulsiona todas as nossas equipas nas suas atividades. É prestada muita atenção a cada detalhe e toque final: das linhas de produtos aos serviços oferecidos, é um padrão que se destaca.

2.4. Atividades da organização

2.4.1. Organograma da empresa

A La Redoute é uma empresa de renome por todo o mundo, inclusive Portugal, tem como principais atividades a venda de produtos que estejam ligados à moda, à casa e ao *outlet*, como ilustra a **Figura 1**.

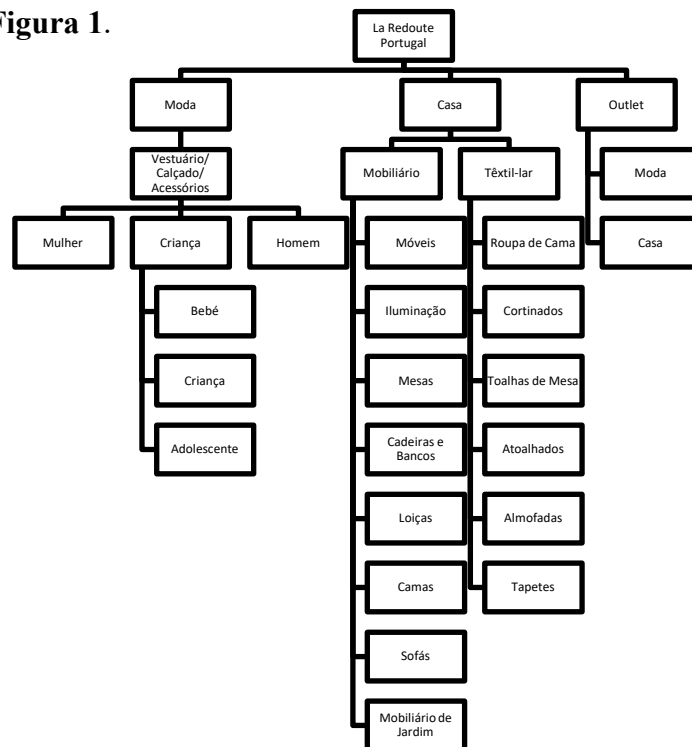


Figura 1 - Produtos vendidos pela La Redoute Portugal. Fonte: Próprio

A **Figura 1** revela que a La Redoute Portugal está organizada em três secções principais: moda, casa e *outlet*, onde se encontram produtos tanto de moda como para o lar.

A secção de moda divide-se em três categorias: moda para mulher, homem e criança, oferecendo roupa, calçado e acessórios. Dentro da moda infantil, existem subcategorias para bebé (até cerca de 4 anos), criança (até 12 anos) e adolescente (até 18 anos), abrangendo diferentes faixas etárias com produtos adequados a cada fase.

Na secção de casa, os produtos estão organizados em duas categorias principais. A primeira é a de têxtil-lar, que inclui cortinas, roupa de cama, almofadas, tapetes, toalhas e outros produtos têxteis. A segunda categoria é dedicada ao mobiliário e decoração, com uma oferta que vai desde móveis e iluminação até loiças, mesas, cadeiras, camas e até mobiliário de jardim. Em todas estas categorias, a La Redoute procura oferecer uma vasta gama de produtos que respondem aos gostos e necessidades dos seus clientes, sempre com preços competitivos e descontos atrativos.

O *website* da La Redoute, sendo o principal canal de vendas da marca, oferece uma vasta seleção de produtos e marcas tanto no segmento de moda como no de casa. Este modelo permite à empresa ter um posicionamento único, combinando qualidade, estilo e preços acessíveis, e satisfazendo as expectativas dos seus clientes, que procuram moda e decoração com um toque de elegância e funcionalidade.

2.5. Caracterização dos Clientes

Sabemos que os clientes vão ser compradores que compartilham uma necessidade ou desejo específico que pode ser satisfeito por meio da troca (Kotler *et al.*, 1999). Contudo, é necessário oferecer valor para o cliente, isto é, a diferença entre os benefícios que o cliente obtém ao possuir e utilizar um produto e os custos associados à sua obtenção (Kotler *et al.*, 1999).

De acordo com a própria La Redoute, a marca tem mais de 10 milhões de clientes mundialmente e o seu *target* passa pelas mãos, sejam elas mais jovens ou mais velhas, onde o foco das suas necessidades vão ser elas mesmo, mas também se centram muito nos seus filhos, na sua roupa, como também em equipamentos para as suas casas.

Além disso, vemos que os clientes da La Redoute são pessoas que adoram a relação qualidade/preço dos produtos da marca, sem nunca esquecer o foco de conseguir inspirar as pessoas com os seus produtos exclusivos (Redoute, 2024).

Mais especificamente, de acordo com os dados retirados do *Google Analytics* do *website* da La Redoute Portugal (**Figura 2**), podemos verificar que o tipo de clientes que procuram a marca, em 2024 (01/01 - 09/12), vão ser sobretudo mulheres, correspondendo a mais de 80% do tráfego. A faixa etária dos clientes da La Redoute Portugal concentra-se em pessoas com mais de 65 anos, sendo seguida pelo grupo etário dos 45-54 anos. Verifica-se, assim, que o público do *website* da La Redoute Portugal é maioritariamente composto por pessoas de idade mais avançada, conforme ilustrado na **Figura 2**. Sabemos também que, estamos perante um público residente em Portugal continental na sua grande maioria, mais especificamente residente na área metropolitana de Lisboa.




Figura 2 - Clientes da La Redoute Portugal. Fonte: Google Analytics da La Redoute Portugal

2.6. Análise SWOT

Neste ponto, serão avaliados os fatores internos e externos que influenciam a empresa La Redoute Portugal, utilizando uma análise SWOT (*Strengths, Weaknesses, Opportunities & Threats*). Essa análise, criada por Kenneth Andrews e Roland Christensen nos anos 60 e popularizada na década de 70, destaca-se como uma ferramenta que orienta a busca por soluções, ajudando na tomada de decisões com base em informações internas e externas (Serra et al., 2011). Através desta análise, as empresas criam estratégias para potenciar os seus pontos fortes, melhorar as fraquezas, aproveitar oportunidades e minimizar ameaças.

Assim sendo, na tabela abaixo foi realizada a análise SWOT da La Redoute Portugal. Esta análise SWOT (**Tabela 1**) foi realizada, por minha autoria, após a recolha de informações dadas pelos colaboradores da La Redoute Portugal e de um pouco de pesquisa própria em relação à organização.

Pontos Fortes	Pontos Fracos
<ul style="list-style-type: none"> • Grande reconhecimento internacional e nacional • Diversidade na oferta de produtos • Pioneira no mercado de <i>E-commerce</i> 	<ul style="list-style-type: none"> • Poucos pontos de venda físicos • Negócio concentrado num público-alvo específico • <i>Marketplace</i>
Oportunidades	Ameaças
<ul style="list-style-type: none"> • Novos comportamentos dos consumidores • Expansão para outro público-alvo • Influenciadores digitais 	<ul style="list-style-type: none"> • Aumento da concorrência ao nível do <i>e-commerce</i> • Compradores menos leais à marca e mais oportunistas • Instabilidade económica nacional e mundial

Tabela 1 - Análise SWOT - La Redoute Portugal. Fonte: Próprio

Os pontos fortes da análise SWOT da La Redoute (**Tabela 1**) remetem para:

- **Grande reconhecimento internacional e nacional:** Com uma história que se estende por mais de 180 anos e uma presença em Portugal há mais de 36 anos, a marca La Redoute distingue-se como uma referência incontornável, tendo um reconhecimento acima de muitas outras marcas.
- **Diversidade na oferta de produtos:** Na La Redoute, os clientes têm acesso a uma vasta gama de artigos que abrange moda, mobiliário, decoração e utensílios para o lar. Esta diversidade permite à marca alcançar diferentes segmentos de consumidores. Além disso, a La Redoute não se limita à diversidade de produtos, disponibiliza também uma seleção variada de marcas.

- **Pioneira no mercado de *E-commerce*:** Sendo uma das primeiras marcas a apostar no comércio eletrônico, tanto a nível global como em Portugal, a La Redoute desenvolveu uma plataforma sólida. Esta infraestrutura permite-lhe atingir um público vasto e oferecer uma experiência prática e conveniente aos seus clientes.

Os pontos fracos da análise SWOT (**Tabela 1**) consistem:

- **Escassez de pontos de venda físicos:** Embora a La Redoute aposte quase exclusivamente no *e-commerce*, a ausência de lojas físicas pode, em certos casos, limitar o seu valor percebido e reconhecimento. Espaços físicos poderiam contribuir para reforçar a notoriedade e a perceção de valor da marca.
- **Dependência de um público-alvo específico:** Atualmente, a La Redoute foca-se sobretudo num segmento particular de clientes - "mães, que sejam mais jovens ou mais maduras, cujas necessidades se centram tanto nelas como nos seus filhos" (Redoute, 2024). Esta concentração num grupo específico torna a marca vulnerável, uma vez que a sua viabilidade está fortemente condicionada à fidelização deste público.
- **Marketplace:** A falta de uma plataforma de *marketplace* na La Redoute Portugal coloca-a em desvantagem face à concorrência, num mercado que está em clara expansão. Este formato já é utilizado, por exemplo, na La Redoute França, o que demonstra o seu potencial para aumentar a popularidade, as receitas e a quota de mercado. A ausência desta funcionalidade limita o crescimento da operação em Portugal.

As oportunidades da La Redoute Portugal (**Tabela 1**) correspondem a:

- **Novos comportamentos dos consumidores:** Ao longo dos anos, os hábitos de consumo têm evoluído significativamente. Este cenário tem impulsionado o crescimento do *e-commerce*, tornando-se uma escolha cada vez mais popular entre os consumidores.

- **Expansão para novos segmentos de mercado:** Atualmente, o sucesso da La Redoute está muito dependente do segmento feminino. Contudo, a marca tem a oportunidade de diversificar, explorando o mercado masculino, especialmente no setor da moda.
Além disso, pode apostar no segmento B2B, promovendo a venda de mobiliário e outros artigos a hotéis, associações de turismo e empresas de restauração, ampliando assim o seu alcance.
- **Potencial dos influenciadores digitais:** No contexto atual, os influenciadores digitais representam uma excelente oportunidade para a La Redoute aumentar a sua visibilidade. A colaboração com estas figuras pode ajudar a marca a atingir um público mais amplo e diversificado.

Por fim, as ameaças apresentadas na **Tabela 1**, resultam em:

- **Aumento da concorrência no e-commerce:** O crescimento do mercado de comércio eletrónico e a sua crescente rentabilidade têm atraído um número crescente de empresas. Esta dinâmica intensifica a concorrência, resultando na perda de quota de mercado por parte da La Redoute para os seus concorrentes.
- **Compradores menos leais à marca e mais oportunistas:** O perfil do consumidor atual tende a ser menos leal a marcas específicas, focando-se sobretudo em encontrar a melhor relação qualidade/preço. Com fácil acesso à informação, os compradores optam frequentemente pela solução mais económica, independentemente da marca.
- **Instabilidade económica nacional e global:** Fatores como recessões, inflação e eventos globais, incluindo conflitos, afetam o poder de compra dos consumidores. Estas flutuações económicas podem alterar significativamente os padrões de consumo, reduzindo a procura por determinados produtos.

3. Programa de Estágio

O estágio foi realizado com base em 5 tarefas ao longo de 640 horas. Conforme a calendarização da **tabela 2**, as tarefas foram distribuídas entre os meses de setembro a janeiro da seguinte forma:

Tarefas/Mês	Setembro	Outubro	Novembro	Dezembro	Janeiro
Mapeamento das categorias por 3 tipologias: <i>core business</i> , recrutamento e complemento		X			X
Calendário de sazonalidade comercial baseado em 3 principais KPI's: <i>PDP Views</i> , <i>Vendas (DAD)</i> e Sazonalidade do mercado (<i>Google Trends</i>)	X	X	X	X	X
Seguimento e tratamento de um questionário enviado a uma audiência de 70 mil clientes sobre a percepção de preço da marca de casa, La Redoute <i>Intèrieurs</i>			X	X	
<i>Benchmark pricing</i> das categorias de móveis relevantes para a atividade da La Redoute				X	
Seguimento do plano comercial dos principais concorrentes dos produtos de casa da La Redoute			X	X	X

Tabela 2 - Plano de Trabalho do estágio na La Redoute Portugal. Fonte: Próprio

3.1. Tarefa 1: Construção de um calendário de sazonalidade

Desempenhei a tarefa de criar um calendário de sazonalidade para estuar padrões em produtos de casa, analisando dados internos e externos. Foi organizado os produtos em categorias com base nas famílias da La Redoute Portugal e recolhi dados do *Google Trends* para comparar com métricas internas, como visualizações de produtos (*PDP Views*) e receitas líquidas (*DAD*), criando índices para cada fonte de dados, calculando a relação de cada valor com a média da categoria.

Para maior precisão, utilizei índices quinzenais em vez de mensais. Com esses dados, desenvolvi um mapa de sazonalidade, indo buscar os valores correspondendo ao mesmo período dos dois anos e fazendo uma média do mesmo. A formatação condicional no *Excel* ajudou a visualização, atribuindo cores específicas a cada nível, de acordo com o valor dentro da categoria do produto. Este processo resultou numa ferramenta prática para identificar padrões sazonais e apoiar decisões estratégicas na empresa.

3.2. Tarefa 2: Mapeamento das categorias produto

Nesta tarefa, o objetivo consistia em criar um mapa para determinadas categorias de produtos para a casa. Este mapa seria um gráfico de dispersão, no qual as variáveis em análise seriam as quantidades de produtos vendidas e o turnover, ou seja, o rendimento que cada categoria proporciona à organização.

As categorias utilizadas no estudo foram: sofás, cadeirões, mobiliário de jardim, mobiliário de sala de estar, mesas e cadeiras, mobiliário de quarto de criança, produtos para casa de banho e cozinha, produtos de cama, mobiliário de quarto de adulto, secretárias, prateleiras, mobiliário de arrumação, tapetes, produtos de iluminação, produtos de decoração, roupa de cama lisa, roupa de cama estampada, edredões e almofadas, cortinados, têxtil de banho, almofadas decorativas, roupa de cama para criança, utensílios de mesa e têxtil de mesa.

Após a construção do mapa, procedeu-se a uma comparação com um mapa semelhante, mas referente à La Redoute de França, no mesmo período. Este processo permitiu identificar as semelhanças e diferenças entre os dois mercados e avaliar quais as categorias com melhor e pior desempenho no mercado da La Redoute Portugal.

3.3. Tarefa 3: Revisão das tendências de produtos para casa

Para esta tarefa, o objetivo consistiu em realizar um breve estudo de mercado para identificar as principais tendências de determinados produtos para o ano de 2024. Este estudo envolveu, numa primeira fase, a análise dos produtos mais procurados pelas marcas concorrentes e o destaque dado a esses produtos nas respetivas redes sociais. Adicionalmente, foi realizada uma pesquisa no *Pinterest*, dado ser uma plataforma amplamente utilizada para inspiração e referência por muitos utilizadores. Paralelamente, analisaram-se os produtos mais visualizados no site da La Redoute Portugal.

Com base na observação dos produtos e na compreensão das tendências presentes no mercado, foram selecionados artigos alinhados com essas tendências. O objetivo foi destacar esses produtos, demonstrando que a empresa acompanha as preferências do mercado e procura atender melhor às expectativas e necessidades dos clientes.

3.4. Tarefa 4: Estudo de questionário realizado pela La Redoute

O objetivo desta tarefa consistiu em analisar as respostas ao questionário elaborado pela La Redoute, com especial foco no estudo das questões de resposta aberta. O trabalho envolveu segmentar estas respostas, atribuindo-lhes uma codificação específica, de modo a identificar, no final, os principais problemas apontados pelos clientes.

A análise destas questões abertas centrou-se, sobretudo, em compreender as vantagens de comprar online e as melhorias sugeridas pelos clientes para a La Redoute Portugal.

3.5. Tarefa 5: *Benchmark Pricing* de categorias dos móveis relevantes para a atividade da La Redoute Portugal

Nesta tarefa o objetivo consistia em determinados produtos, fazer uma comparação de preços dos produtos da La Redoute e os seus principais concorrentes para ver em que produtos a La Redoute se encontrava com preços mais baixos e mais altos e, a partir deste estudo ser feita uma avaliação dos preços e possivelmente um ajustamento do mesmo, indo mais ao encontro dos preços que as outras marcas praticam, de maneira a tentar melhorar a sua quota de mercado.

4. Problema de Investigação

4.1. Revisão da Literatura

4.1.1. Comportamento do Consumidor

Estudar o comportamento do consumidor é importante para descrever o estudo de como as pessoas escolhem, compram, utilizam e descartam produtos, experiências, ideias e serviços para atender às suas necessidades, assim como o impacto dessas ações no próprio consumidor e na sociedade (Roy & Datta, 2022).

Vemos que o estudo do comportamento do consumidor envolve processos psicológicos que identificam as necessidades e procuram soluções para as satisfazer, onde as pessoas decidem o que comprar, avaliam as informações recolhidas, elaboram o seu plano e o executam (Anderson & Golden, 1984). Ou seja, vemos que o comportamento do consumidor e o seu comportamento de compra acaba por ser uma culminação das suas preferências, opiniões, objetivos e decisões em resposta ao mercado ao adquirir um produto (Schiffman & Kanuk, 1991).

Para isso, é importante que haja um forte envolvimento com o produto para que resolva o problema que começa com a conscientização do problema e avança através da procura de informações, avaliação de produtos alternativos e compra, e atividades pós-compra (Engel *et al.*, 1986). Além disso, a procura ativa por informação e o processamento dessa informação são considerados passos naturais no processo de decisão racional, sendo que pode influenciar as decisões futuras dos consumidores, levando à revisão das suas atitudes e intenções após a compra (Festinger, 1957).

Diversos modelos e teorias procuram explicar esse processo em detalhe, destacando como o comportamento do consumidor é moldado por uma interação entre fatores internos e externos (Roy & Datta, 2022).

4.1.1.1. Teorias e Modelos de Comportamento do Consumidor

Constatamos que o comportamento do consumidor é um campo complexo, abrangendo diversas teorias no seu estudo em que, cada uma delas oferece uma perspetiva única sobre como as decisões de compra são influenciadas por diversos fatores como os fatores psicológicos, sociais e económicos.

- **Teoria da Ação Racional**

Tendo por base a Teoria da Integração da Informação, que adiciona a intenção comportamental como uma componente chave, a Teoria da Ação Racional foca-se em que o comportamento do consumidor é explicado através da intenção comportamental, que é influenciada por dois fatores principais: as atitudes em relação ao comportamento (avaliações positivas ou negativas sobre realizar uma ação) e as normas subjetivas (percepção das pressões sociais para realizar ou não o comportamento). Esta teoria reconhece que a intenção comportamental é o principal preditor do comportamento real, embora existam fatores que possam limitar a sua influência. Neste caso, as intenções de comportamento são motivadas por atitudes e normas sociais, levando às ações de compra (Fishbein & Ajzen, 1975).

- **Teoria do Comportamento do Comprador**

Esta abordagem baseia-se na ideia de que o comportamento de compra é influenciado por uma complexa interação de fatores internos e externos. Estes incluem estímulos ambientais (como cultura, classe social e influências situacionais) e características pessoais (como motivações, percepções e atitudes). A teoria propõe que o processo de decisão do consumidor é dinâmico e envolve a interação entre *inputs* (estímulos), processos psicológicos (como percepção e aprendizagem) e *outputs* (resultados), como a decisão de compra e a satisfação. Além disso, a teoria enfatiza que as decisões de compra não são apenas racionais, mas também moldadas por fatores emocionais e contextos sociais, destacando a importância de uma abordagem holística para compreender o comportamento do consumidor (Howard & Sheth, 1969).

- **Teoria da Hierarquia das Necessidades de Maslow**

Esta teoria propõe que o comportamento do consumidor é impulsionado pela tentativa de satisfazer cinco necessidades básicas: fisiológicas, segurança, sociais, autoestima e autorrealização. Ou seja, os consumidores procuram primeiro satisfazer as suas necessidades básicas antes de passarem para necessidades superiores. Esta hierarquia de necessidades influencia as decisões de compra, uma vez que a satisfação de cada nível motiva o seu comportamento (Maslow, 1943).

- **Teoria de Compra por Impulso**

Segundo esta abordagem, é sugerido que muitos comportamentos de compra são impulsivos, sendo frequentemente desencadeados por estímulos externos e não por decisões racionais ou bem planejadas. Este comportamento de compra impulsiva é visto como uma exceção ao comportamento de compra racional, destacando como certos estímulos podem levar a decisões de compra imediatas (Stern, 1962).

- **Modelo de Aprendizagem**

Este modelo sugere que o comportamento de compra pode ser influenciado através da associação entre estímulos. Demonstrou-se que um estímulo neutro (como um som) pode eliciar uma resposta condicionada (como salivação) quando repetidamente associado a um estímulo incondicionado (como comida). No contexto do comportamento do consumidor, esse princípio pode ser aplicado para associar marcas ou produtos a sentimentos positivos, criando uma resposta condicionada favorável (Pavlov, 1927).

- **Modelo Multiatributo**

Este modelo destaca que os consumidores avaliam as marcas com base em vários atributos. Cada atributo contribui na combinação ponderada das crenças sobre os atributos (a percepção do consumidor sobre a presença ou ausência de cada atributo) e da avaliação desses atributos (a importância que o consumidor atribui a cada um). Assim, as empresas podem influenciar as atitudes e os comportamentos dos consumidores, melhorando os atributos percebidos ou introduzindo novos atributos que atendam às expectativas do mercado. (Ajzen & Fishbein, 1980).

- **Modelo de Nicosia**

Este modelo foca-se sobretudo na fase de pré-compra e considera o comportamento do consumidor como algo dinâmico e interativo com a empresa. Ele vê o processo de tomada de decisão do consumidor como uma interação entre a empresa, que envia mensagens e estímulos, e o consumidor, que responde a essas influências (Nicosia, 1966).

Este modelo divide-se em quatro campos. Primeiramente, a empresa inicia a interação com o consumidor através de mensagens publicitárias, enquanto o consumidor, com base nas suas características e percepções, processa essas informações (Campo 1). Com isso, o consumidor procura e avalia informações sobre o produto. A imagem que o consumidor tem da empresa pode influenciar este processo (Campo 2). De seguida, acontece o processo de decisão de compra, onde o consumidor decide se compra ou não o produto (Campo 3). Por fim, analisamos o comportamento pós-compra do consumidor, incluindo a satisfação ou insatisfação, que afeta o comportamento futuro e a lealdade à marca (Campo 4) (Nicosia, 1966).

- **Modelo EKB**

Este modelo tem uma abordagem bastante detalhada e estruturada para entender como os consumidores tomam decisões. Nele, o processo da decisão de compra divide-se em cinco estágios principais, sendo eles: Reconhecimento do problema; Procura de informações; Avaliação de alternativas; Decisão de compra e Comportamento pós-compra (Engel *et al.*, 1986).

O mesmo também tem em consideração fatores como entrada de informações (de fontes de *marketing* e não-*marketing*), processamento de informações (como os consumidores percebem e interpretam os dados) e fatores de influência (sociais, situacionais e pessoais) (Engel *et al.*, 1986).

4.1.1.2. Fatores que influenciam as decisões de compra dos consumidores

O comportamento do consumidor é influenciado por uma variedade de fatores pessoais, sociais, culturais e emocionais, que moldam suas decisões de compra, sendo necessária à sua compreensão para que se consiga ter uma melhor percepção do que pode, ou não, influenciar os consumidores.

Os fatores pessoais como a idade, rendimento, personalidade e estilo de vida do indivíduo mostram que o comportamento de compra difere, de acordo com as características de cada um (Roy & Datta, 2022). Por exemplo, diferentes fases da vida exigem produtos diferentes, e o nível de rendimento afeta o tipo de produtos que o consumidor pode comprar. Também, a personalidade um papel diretamente ligado às escolhas de consumo, uma vez que os consumidores procuram produtos que reforcem a sua identidade (Roy & Datta, 2022).

Outro aspeto a ter em conta no momento de compra por parte dos consumidores é a preocupação com o bem-estar e com a saúde por parte dos consumidores e de este ser um dos principais motivadores nas decisões de compra de produtos (Cheah, 2014). Consumidores com maior consciencialização com problemas de saúde tendem a valorizar produtos que promovam a saúde e o bem-estar. Essa preocupação com a saúde reflete uma procura por produtos que agreguem benefícios pessoais, o que influencia diretamente suas escolhas de consumo (Cheah, 2014).

No campo social, as interações com grupos de referência, como amigos ou família, desempenham um papel fundamental. Consumidores que estejam expostos a opiniões e recomendações de outros, são influenciados pelo desejo de aceitação e pertencimento (Nespolo *et al.*, 2015). Isso é particularmente evidente em ambientes digitais, onde a validação social e a interação nas redes promovem uma maior disposição para seguir tendências, impulsionando a compra de produtos populares entre seus pares (Nespolo *et al.*, 2015).

Culturalmente, as normas e valores de uma sociedade moldam o comportamento de compra. Subculturas e classes sociais também desempenham um papel significativo, influenciando as preferências e escolhas dos consumidores com base em suas tradições e *status* socioeconómico (Medeiros & Cruz, 2006). Estas subculturas podem ser baseadas em religião, etnia ou localização geográfica e influenciam as preferências e decisões de compra (Medeiros & Cruz, 2006). A classe social é outro ator cultural importante que influencia o comportamento de compra, pois, consumidores de diferentes classes sociais tendem a ter gostos, preferências e hábitos de compra diferentes (Roy & Datta, 2022).

Também, a sensibilidade ao preço desempenha um papel importante, especialmente em mercados de consumidores que valorizam descontos e promoções. Nesses mercados pode-se constatar que que estratégias de desconto podem impulsionar as compras impulsivas, uma vez que o valor percebido aumenta com a redução do preço (Lucena *et al.*, 2011). Promoções e ofertas especiais tornam o produto mais atrativo e incentivam o consumidor a finalizar a compra (Lucena *et al.*, 2011).

Por fim, os fatores emocionais incluem a percepção, o impulso de compra, crenças e atitudes. A forma como o consumidor interpreta as informações, o desejo repentino de comprar algo, e a confiança numa marca ou produto são determinantes no processo de compra (Roy & Datta, 2022). Por exemplo, a percepção que é a forma como o consumidor interpreta as informações recebidas, é um fator emocional chave. Cada indivíduo pode perceber um produto ou uma marca de maneira diferente, dependendo das suas experiências anteriores e das suas necessidades no momento (Kotler, 1998). Outro fator emocional importante é o impulso, que se refere ao desejo repentino de fazer uma compra, muitas vezes sem planeamento prévio (Roy & Datta, 2022).

Estas compras por impulso são bastante comuns e podem ser desencadeadas também, por estímulos externos, como promoções ou publicidade apelativa (Roy & Datta, 2022). Estes impulsos, podem ser compreendidas através da teoria de motivação de Freud, que embora não aborde diretamente o comportamento do consumidor, o mesmo sugere que muitos dos nossos comportamentos são guiados por desejos e impulsos inconscientes (Freud, 1915). Estímulos externos, como uma promoção atrativa, podem ativar esses impulsos internos, levando o consumidor a agir sem uma análise racional completa, mas com base em desejos latentes e emoções reprimidas (Freud, 1915).

4.1.1.3. Comportamento de Compra *Online*

O comportamento de compra *online* tem sido objeto de crescente interesse, especialmente com a digitalização progressiva da sociedade e a expansão do *e-commerce*. Ele se refere às ações e decisões dos consumidores quando utilizam a *Internet* para adquirir produtos ou serviços. Esse comportamento é influenciado por diversos fatores, como a conveniência, o preço, as recomendações de terceiros, entre outros (Chen & Dubinsky, 2003).

Atualmente, as pessoas preferem a escolha por comprar *online* pelo facto de as compras *online* apresentam uma maior conveniência que as compras em lojas físicas (Sarkar & Das, 2017). Verifica-se que, o *e-commerce* proporciona uma maior flexibilidade de tempo, acessibilidade, sem barreiras geográficas, maior facilidade de comparar preços rapidamente, maior diversidade de produtos que são limitados em lojas tradicionais. Além disso, as plataformas *online* facilitam a procura por produtos específicos, eliminando a necessidade de percorrer longas distâncias ou de enfrentar multidões (Sarkar & Das, 2017).

Outro fator importante é a percepção de menores custos ao comprar *online*, tanto em termos de tempo quanto de dinheiro. Os consumidores veem as lojas *online* como uma forma de economizar não apenas pelo fato de que podem encontrar promoções mais frequentemente, mas também pela eliminação de custos associados ao deslocamento até as lojas físicas (Vithayathil *et al.*, 2020).

Também, a variedade de produtos disponíveis nas plataformas *online* é outro motivo pelo qual os consumidores preferem o comércio eletrônico (Imran *et al.*, 2022).

A facilidade de encontrar produtos raros ou especializados *online* supera as limitações de inventário das lojas físicas. No contexto da pandemia de COVID-19, essa preferência foi intensificada, já que muitos consumidores migraram para plataformas *online* na procura de produtos que não estavam disponíveis nas lojas próximas devido a restrições de *stock* (Imran *et al.*, 2022).

Por outro lado, embora o *online* ofereça várias vantagens, a experiência de compra em lojas físicas, como a possibilidade de experimentar produtos e a interação direta com vendedores, ainda exerce um papel importante em certas categorias de consumo (Florenthal & Shoham, 2010). Alguns consumidores ainda preferem a experiência tátil e visual proporcionada pelas lojas físicas, especialmente ao comprar roupas, móveis ou outros itens que exigem uma avaliação mais detalhada (Florenthal & Shoham, 2010).

Constatamos que o *e-commerce* apesar de já ser um mercado em crescimento, o mesmo teve um pico de procura durante a pandemia. Devido à pandemia de COVID-19, o comportamento de compra mudou significativamente, com muitos consumidores a optar por fazer as suas compras *online*, invés de se deslocar às lojas, isto porque durante esse período tinham medo de serem infetadas (Grashuis *et al.*, 2020). Com isto, com o fim da pandemia, muitos dos consumidores já habituados com a comodidade das compras *online* acabou por manter o seu comportamento de compra, dando a importância que, hoje em dia, o *e-commerce* tem (Grashuis *et al.*, 2020).

4.1.1.3.1. Fatores Decisivos na Escolha das Compras pelo *Online*

A confiança nas plataformas de *e-commerce* e a experiência positiva em compras anteriores são determinantes para que consumidores continuem a fazer compras *online* (Liu *et al.*, 2013). A familiaridade com a tecnologia e a percepção de segurança no ambiente digital reduzem as barreiras ao consumo *online*, enquanto consumidores que experimentaram problemas como atrasos ou falta de suporte são mais propensos a voltar a comprar nas lojas físicas (Liu *et al.*, 2013).

Outro aspeto de as pessoas preferirem comprar produtos *online* tem a haver com o facto da conveniência que o processo traz. A flexibilidade de horários e a facilidade de comparar produtos e preços *online* oferecem uma experiência de compra prática e sem complicações, preferida por consumidores ocupados e de diversas faixas etárias (Aris *et al.*, 2021).

Este aspeto de se poder comparar preços rapidamente é um grande motivo para os consumidores optarem pelo *online* em vez do físico (Chandra & Sinha, 2013). Promoções e descontos exclusivos, muitas vezes oferecidos em plataformas digitais, são um atrativo adicional, fazendo com que o comércio *online* pareça mais económico (Chandra & Sinha, 2013).

No entanto, a compra de produtos *online* vai ter sempre um aspeto muito influenciador para que se o mesmo possa vir a ter sucesso ou não. É essencial que neste mercado que exista confiança por parte dos consumidores na segurança das transações (Rajesh, 2018). Por isso, é essencial que as empresas invistam em certificados de segurança e políticas de proteção de dados para ganharem a preferência dos consumidores, sobretudo daqueles que se preocupam com a proteção de informações financeiras e pessoais durante o processo de compra (Rajesh, 2018).

Para além da segurança, as empresas também devem investir noutros aspetos para ter sucesso no mercado *online*, sendo um deles investir numa interface simples do seu *website* (Chen *et al.*, 2012). *Websites* com uma interface de difícil percepção por parte dos consumidores, ao não valorizar a praticidade e simplicidade pode prejudicar o seu desempenho no mercado *online* (Riquelme & Rios, 2010). Para além disso, as empresas também devem ter em atenção em terem um bom suporte ao cliente e políticas de devolução flexíveis para que as pessoas se sintam mais interessadas em comprar *online* em vez de optarem por ir à loja, aumentando a sua confiança neste processo (Dholakia & Zhao, 2010).

4.1.2. Data Science

A ciência dos dados, ou *data science*, é um conjunto de princípios fundamentais que orientam a extração de informações e conhecimento a partir de dados. Embora não seja possível definir de forma precisa o que é a ciência dos dados, sabemos que está intimamente relacionada a conceitos como *big data* e à tomada de decisão orientada por dados (*data-driven decision making*) (Provost & Fawcett, 2013). Assim, a ciência dos dados vai além da simples análise técnica dos números, exigindo uma compreensão profunda dos princípios da análise causal e das metodologias estatísticas que sustentam esta disciplina.

Métodos eficazes de visualização de dados são essenciais, e existem áreas onde a intuição, criatividade e o conhecimento prático de uma aplicação específica desempenham um papel crucial. Dessa forma, a perspectiva oferecida pela ciência dos dados proporciona uma estrutura sólida para a extração sistemática de conhecimento útil a partir dos dados (Provost & Fawcett, 2013).

Embora a mineração de dados (*data mining*) seja uma componente importante da ciência dos dados, há outros princípios fundamentais que também devem ser compreendidos para uma aplicação eficaz em diversas áreas (Provost & Fawcett, 2013). Além disso, a ciência dos dados envolve mais do que apenas algoritmos de mineração de dados. É necessária a capacidade de abordar problemas de negócios a partir de uma perspectiva baseada em dados, utilizando princípios de análise causal, visualização de dados e criatividade (Provost & Fawcett, 2013).

4.1.3. Análise de Dados

A análise de dados, no contexto de *Big Data Analytics*, é vista como um processo de apoio aos decisores na interpretação de grandes volumes de dados. Este processo faz parte da transformação de dados em conhecimento útil para as empresas (Ackoff, 1989). Este procedimento envolve um conjunto de metodologias quantitativas e qualitativas que permitem interpretar os dados e extrair a informação mais relevante (Chatfield, 1995a).

Com o apoio da *machine learning*¹, os dados são organizados de forma a permitir a extração de informações úteis, como o desempenho dos clientes, as preferências e tendências de mercado, bem como detalhes de contacto, que podem ser usados pelas empresas para o desenvolvimento das suas estratégias (Vrontis *et al.*, 2021; Tseng *et al.*, 2022).

Embora os dados geralmente respondam a uma pergunta específica, podem também revelar padrões inesperados, proporcionando uma compreensão mais profunda do problema em análise ou mesmo de questões que até então não tinham sido identificadas pela empresa (Chatfield, 1995a).

Em suma, a análise dos dados detidos pelas empresas pode influenciar diversos fatores internos, conferindo-lhes capacidades adicionais, tal como nos mostra a **Tabela 3** (Adrian *et al.*, 2018).

Fatores	Variáveis
Capacidade de Gestão	<ul style="list-style-type: none"> • Tomada de decisão sobre investimentos • Coordenação e controlo
Capacidade Organizacional	<ul style="list-style-type: none"> • Base estratégica • Apoio à gestão de topo • Prontidão empresarial
Capacidade Tecnológica	<ul style="list-style-type: none"> • Flexibilidade da infraestrutura • Integração e padronização de processos
Capacidade de Processamento de Informação	<ul style="list-style-type: none"> • Capacidade analítica • Padrões de cuidado • Capacidade de suporte à decisão • Velocidade nas decisões

Tabela 3 - Capacidades da Análise de dados: Fatores e Variáveis. Adaptado de: Adrian *et al.*, 2018

¹ *Machine learning* é uma técnica que permite aos sistemas aprender e melhorar automaticamente a partir de dados sem a necessidade de programação explícita, sendo fundamental para processar grandes volumes de informação e gerar previsões mais precisas (Zytek *et al.*, 2021).

4.1.3.1. Qualidade das bases de dados

A qualidade dos dados armazenados por uma organização é essencial para que os colaboradores possam obter um conhecimento mais profundo e preciso sobre os clientes, desempenhando assim um papel crucial na sua retenção. Isto porque a qualidade dos dados é um fator determinante para melhorar a qualidade da tomada de decisão (O'Reilly, 1982; Keller & Staelin, 1987).

Além disso, as bases de dados permitem que as empresas, através dos dados recolhidos com base nas perceções dos clientes, ofereçam serviços personalizados (Wu, 2022). Compreender as preferências dos clientes e lidar de forma proativa com as suas preocupações pode aumentar a sua satisfação e, conseqüentemente, a sua lealdade (Wu, 2022). Para isso, é fundamental que exista uma variedade de fontes de dados, uma vez que a integração de diferentes fontes e as variações na qualidade entre elas requerem mecanismos de controlo que garantam a contextualização e o processamento adequado dos dados (Janssen *et al.*, 2014).

Diversos estudos apontam que existem diversos fatores a ter em conta (**Tabela 4**), para que a base de dados utilizada por uma empresa seja uma base de dados de qualidade e crucial no desempenho organizacional (Adrian *et al.*, 2018).

Fatores	Variáveis
Qualidade dos Dados	<ul style="list-style-type: none"> • Consistência dos dados • Completude dos dados
Qualidade da Informação	<ul style="list-style-type: none"> • Atualidade • Precisão • Segurança e integridade
Qualidade do Sistema	<ul style="list-style-type: none"> • Fiabilidade • Adaptabilidade • Integração • Acessibilidade • Privacidade do sistema

Tabela 4 - Qualidades das bases de dados: Fatores e Variáveis. Adaptado de: Adrian *et al.*, 2018

4.1.3.2. Qualidade da tomada de decisão

A eficácia da tomada de decisão é definida tanto pela qualidade das decisões como pela capacidade de alcançar os resultados desejados (Visinescu *et al.*, 2017). Assim, o processo de tomada de decisão desempenha um papel crucial no desempenho de uma empresa, com o objetivo de gerar resultados sustentáveis (Beiragh *et al.*, 2020; Zehir *et al.*, 2020). É essencial que as decisões sejam eficazes e sustentáveis, suportadas pelos dados da organização, de modo a identificar e enfrentar os desafios presentes e futuros (Klatt & Smeeton, 2020). Quando a tomada de decisão é bem fundamentada, contribui para que as empresas alcancem resultados mais positivos e rentáveis. No entanto, para melhorar a qualidade das decisões, a empresa deve continuamente aperfeiçoar a qualidade e o processamento da informação recolhida (Raghunathan, 1999). A qualidade das decisões aumenta quando o decisor compreender as relações entre as variáveis do problema (Raghunathan, 1999).

A integração da análise de dados e a utilização de métodos quantitativos também desempenham um papel fundamental na melhoria da qualidade das decisões. Empresas que utilizam a análise de dados como suporte tendem a ser mais competitivas, uma vez que conseguem identificar padrões de desempenho e prever tendências futuras com maior precisão (Davenport & Harris, 2007). Além disso, estas ferramentas proporcionam uma visão mais clara dos fatores que afetam o desempenho, permitindo aos líderes tomar decisões mais rápidas e informadas (Hazen *et al.*, 2014). O uso de métricas e indicadores de desempenho facilita a monitorização dos resultados, permitindo ajustes contínuos e uma resposta mais eficiente aos desafios (Kaisler *et al.*, 2013).

Outro aspeto importante para uma boa tomada de decisão é a integração tecnológica nos processos organizacionais, que aumenta a eficácia das decisões ao permitir que as organizações tomem decisões baseadas em dados concretos, relevantes e em tempo real (Shamim *et al.*, 2019a, b). Esta integração tecnológica, adaptada à análise de dados, eleva a eficiência operacional, refletindo-se diretamente na qualidade das decisões tomadas (Lin *et al.*, 2020).

Ou seja, vemos que existem diversos fatores a ter em conta para que no momento da tomada de decisão, esta possa ser feita com qualidade, tendo por base a análise de dados (**Tabela 5**). Neste caso, a qualidade da decisão não depende apenas dos dados em si, mas também da forma como os dados são processados e da capacidade de análise dentro das organizações (Janssen *et al.*, 2017).

Dimensões de Influência	Descrição
Gestão Contratual	Formalização de acordos entre organizações para garantir a qualidade dos dados.
Capacidades de Análise de dados	Uso de técnicas analíticas avançadas capazes de interpretar grandes volumes de dados.
Qualidade dos Dados	Dados de alta qualidade são essenciais, já que dados imprecisos podem levar a decisões erradas.
Qualidade dos Tomadores de Decisão	A experiência dos decisores melhora a interpretação e a eficácia das decisões.
Colaboração e Troca de Conhecimento	A colaboração entre participantes é crucial para decisões informadas e integradas.
Padronização	Importante para a automação e utilização contínua de dados, facilitando o fluxo de informações entre as etapas do processo decisório.
Infraestrutura Flexível	Sistemas integrados que facilitam o processamento de dados ajudam a reduzir o tempo necessário para gerar <i>insights</i> e tomar decisões.

Tabela 5 - Fatores que influenciam a qualidade da tomada de decisão. Adaptado de: Janssen *et al.*, 2017

Além dos fatores que vão ser capazes de influenciar a tomada de decisão por parte do decisor dentro de uma empresa, existem dois principais paradigmas no momento da tomada de decisão (Chengalur-Smith, 1999):

- **Decisão Conjuntiva:** A decisão baseia-se num conjunto de critérios conhecidos, em que cada critério tem um nível mínimo aceitável. O decisor deve escolher entre várias opções, mas apenas uma opção é considerada aceitável se atender a todos os critérios estabelecidos. Se falhar num critério, a opção é descartada. Esta abordagem é não compensatória, pois não permite trocas entre critérios.

- **Decisão Aditiva Ponderada:** Nesse paradigma, os critérios de decisão são ponderados com base na sua importância. As opções são avaliadas com base nos critérios e os resultados são multiplicados pelos pesos dos critérios. A opção com a maior pontuação somada é a escolhida. Esta estratégia é compensatória, permitindo trocas entre critérios (um critério com valor mais baixo pode ser compensado por um com uma pontuação mais alta).

Um aspeto a ter em consideração é que, em ambientes de informação mais complexos, os decisores podem ignorar informações consideradas menos relevantes, o que pode influenciar o impacto da informação sobre a qualidade dos dados nesses contextos (Grether *et al.*, 1986).

4.1.3.3. O impacto da análise de dados na tomada de decisão

A análise de dados, especialmente no contexto de *Big Data Analytics*, podemos perceber que este processo está intimamente ligado ao processo empresarial, nomeadamente através de previsões. Estas previsões ajudam as empresas a tomar decisões mais inteligentes e precisas, como facilitar a alocação de recursos (Chatterjee *et al.*, 2023). Um exemplo é o *Walmart*, que recolhe milhares de dados dos seus clientes e estuda-os para compreender melhor o comportamento de compra, resultando num aumento das receitas (Bradlow *et al.*, 2017). Com o uso de tecnologias como *RFID*² e rastreamento por *GPS* dentro das lojas, é possível monitorizar o percurso dos clientes e a sua interação com os produtos (Bradlow *et al.*, 2017). Com isso vemos um caso da importância da integração de dados, podendo este ser *online* ou *offline*, para calcular o valor vitalício do cliente, ajudando a otimizar campanhas de *marketing* e decisões de preço (Bradlow *et al.*, 2017). Este caso demonstra como os dados promovem inovação dentro das empresas, permitindo a criação de novos produtos ou serviços que respondem melhor às necessidades dos clientes (Bradlow *et al.*, 2017).

O impacto dos dados na tomada de decisão é evidente, como demonstrado por um estudo de Erik Brynjolfsson e colegas, que concluiu que quanto mais orientada por dados for uma empresa, maior será a sua produtividade, com aumentos entre 4% e 6% (Provost & Fawcett, 2013).

² A tecnologia *RFID* (*Radio Frequency Identification*) é descrita como um sistema de identificação por ondas de rádio que permite rastrear produtos em tempo real, otimizando a gestão de inventário e o comportamento dos clientes nas lojas (Larson *et al.*, 2005).

A análise de dados, através de capacidades dinâmicas que permitem às empresas integrar, reconfigurar e transformar os seus recursos internos e externos, também lhes dá uma resposta mais eficaz às mudanças no mercado (Teece *et al.*, 1997). Isso permite que as organizações aproveitem oportunidades externas e se ajustem rapidamente às novas condições de mercado, mantendo uma vantagem competitiva sustentável (Chatterjee *et al.*, 2023). Além disso, a análise de dados ajuda as empresas a identificar e mitigar os riscos associados às mudanças no mercado, contribuindo para uma maior resiliência (Chatterjee *et al.*, 2023).

Os dados influenciam ainda o tipo de liderança dentro de uma empresa, moldando a forma como os líderes gerem a informação e tomam decisões. Uma liderança que prioriza o uso de *big data* melhora a governabilidade, promovendo a troca de conhecimento e a colaboração organizacional, criando um ambiente mais propício a decisões estratégicas e informadas (Appleyard *et al.*, 2020; Corte-Real *et al.*, 2020). Assim, torna-se essencial incorporar esses dados e alinhá-los com os objetivos organizacionais (Shamim *et al.*, 2019a, b).

No entanto, embora a *Big Data Analytics* ofereça inúmeros benefícios para a sustentabilidade das empresas, acarreta também desafios, nomeadamente no que diz respeito à necessidade de garantir a privacidade e a segurança dos dados (Neirotti *et al.*, 2021). As empresas devem implementar medidas rigorosas para proteger as informações dos clientes (Neirotti *et al.*, 2021). Algumas formas de como as empresas podem proteger as informações dos clientes é ter uma proteção dos dados sensíveis através de técnicas de criptografia robustas, implementar políticas rigorosas de acesso, garantindo que apenas usuários autorizados possam ter acesso a informações sensíveis (Sivarajah *et al.*, 2017). Também, as empresas, para reduzir os riscos de fuga de informações privilegiadas, podem tornar os dados pessoais anónimos, antes de ser feita a análise, assim como, fazer uma avaliação para identificar potenciais riscos e definir medidas de mitigação específicas antes de qualquer processamento de dados (Mantelero, 2014).

Por fim, é crucial que as empresas disponham de profissionais qualificados para garantir que a recolha e análise dos dados sejam feitas de forma a assegurar a sua fiabilidade e relevância (Chatterjee *et al.*, 2023).

A gestão de talentos na área de análise de dados envolve não só a contratação de especialistas, mas também a atualização constante das competências dos colaboradores à medida que as tecnologias evoluem (Khalil & Belitski, 2020). A transformação de dados em conhecimentos (*insights*) valiosos não acontece automaticamente, sendo necessário contar com profissionais capacitados para analisar e interpretar os dados de forma eficaz (Gupta *et al.*, 2020).

4.1.4. Papel da sazonalidade no *e-commerce*

A sazonalidade é uma componente das séries temporais, caracterizada por padrões que se repetem periodicamente em intervalos curtos e regulares. Estes padrões são particularmente evidentes em setores como o comércio, onde a procura por produtos é influenciada por eventos sazonais (Makridakis *et al.*, 1984). Estes eventos, que ocorrem em intervalos fixos, são previsíveis devido à sua natureza recorrente (Box *et al.*, 2015).

Deste modo, os produtos sazonais destacam-se pelo aumento da procura num período específico, sendo praticamente inexistente no resto do tempo (Kumaresan & Saravanan, 2020). Por isso, é crucial estudar a sazonalidade, já que ignorá-la nos sistemas de recomendação pode diminuir a satisfação dos utilizadores ao sugerir produtos fora de época (Kumaresan & Saravanan, 2020). Para evitar isso, os sistemas devem identificar e ajustar esses produtos ao calendário adequado, sugerindo-os apenas quando são mais relevantes, melhorando assim a experiência do utilizador e a eficácia das recomendações (Kumaresan & Saravanan, 2020).

Além disso, a sazonalidade desempenha um papel fundamental na melhoria da precisão das previsões de vendas, ajudando a determinar que produtos devem ser destacados no mercado *online*. Com base nestas antevisões, é possível implementar sugestões de preenchimento automático (*Query Autocomplete*³), priorizando as pesquisas mais relevantes em períodos específicos (Verma *et al.*, 2023). Isto permite que as plataformas de comércio eletrónico antecipem as necessidades dos consumidores, aumentando as visualizações e promovendo a fidelização do público (Verma *et al.*, 2023).

³ *Query Autocomplete* é uma técnica que sugere complementos para consultas parciais, utilizando abordagens baseadas em registos antigos, modelos probabilísticos e aprendizado de máquina para otimizar a experiência do usuário em sistemas de pesquisa (Verma *et al.*, 2023).

Embora existam produtos com padrões sazonais previsíveis e picos de procura em épocas específicas, no contexto do *e-commerce*, estes períodos são muitas vezes caracterizados por volatilidade e de curta duração (Garnier & Belletoile, 2019; Verma *et al.*, 2023). Esta dinâmica complica a gestão da procura, dado que os períodos sazonais podem ser influenciados por fatores externos como alterações de preços, promoções ou mesmo a disponibilidade dos produtos (Garnier & Belletoile, 2019).

Para enfrentar estes desafios, uma das principais estratégias utilizadas no mercado *online* são as promoções sazonais, direcionadas para períodos específicos. Estas promoções têm como objetivo impulsionar as vendas de produtos e serviços mais procurados nessas épocas (Sardana *et al.*, 2018). Estas iniciativas não só aumentam o tráfego *online*, como também criam um sentido de urgência que estimula compras impulsivas, especialmente quando ocorrem antes de períodos festivos (Shamout, 2016; Sujata & Menachem, 2017). Nestes períodos, a tendência de compra intensifica-se, e as promoções, ao reduzirem os preços, tornam os consumidores mais propensos a adquirir os produtos (Jiang *et al.*, 2018).

4.1.4.1. A importância da Análise de Dados na identificação de padrões sazonais

A identificação de padrões sazonais é uma componente essencial na análise de dados, permitindo compreender de forma mais aprofundada fenómenos periódicos. Estes fenómenos podem ser influenciados por fatores naturais, sociais ou económicos, e a sua análise adequada proporciona vantagens significativas em termos de previsão e gestão de recursos (Hyndman & Athanasopoulos, 2021). Exemplos destas vantagens incluem o apoio às empresas no planeamento de *stocks*, campanhas publicitárias e operações logísticas (Hyndman & Athanasopoulos, 2021).

Ao analisar dados, especialmente em produtos ou serviços mais sujeitos a padrões sazonais, torna-se possível identificar os melhores e os piores períodos para ajustar a oferta à procura existente no mercado (Shugan & Radas, 2000). Em períodos de alta procura, pode-se aumentar a oferta em variedade e volume, enquanto em períodos de baixa procura, as promoções ajudam a mitigar dificuldades (Shugan & Radas, 2000). Além disso, a análise de dados permite identificar padrões de compra sazonais, proporcionando uma melhor compreensão dos comportamentos dos consumidores e permitindo ajustar estratégias para maximizar as receitas, sobretudo nos períodos de elevada procura (Shugan & Radas, 2000).

Assim, a análise de padrões sazonais desempenha um papel central no planeamento estratégico das empresas, favorecendo uma gestão mais eficiente de recursos, uma previsão mais precisa das receitas e um melhor alinhamento com as necessidades do mercado (Shugan & Radas, 2000). A partir dos dados recolhidos e analisados, as empresas obtêm conhecimento que lhes permite planear investimentos e despesas de forma mais eficiente, facilitando o planeamento financeiro (Parrilla *et al.*, 2007).

Em empresas onde a sazonalidade tem um impacto mais acentuado, uma análise de dados bem estruturada permite diversificar os produtos ou serviços oferecidos (Shugan & Radas, 2000). Este processo possibilita a criação de um “mapa” que identifica quais os produtos ou serviços mais relevantes para a empresa ao longo do ano, permitindo o ajuste das estratégias de acordo com essas informações (Shugan & Radas, 2000). Em última análise, uma análise sazonal ajuda as empresas a mitigar os riscos do negócio, capacitando-as para identificar e lidar com riscos associados a flutuações imprevisíveis, como alterações nos padrões de consumo, e ajustar as suas estratégias em conformidade (Oh *et al.*, 2022).

4.1.4.2. Ferramentas de Análise de Dados para identificar sazonalidade

A identificação da sazonalidade em séries temporais é uma tarefa fundamental em diversos domínios, sendo que, ao longo das décadas, várias ferramentas e métodos analíticos foram desenvolvidos para abordar estes padrões (Hyndman & Athanasopoulos, 2021). Uma das técnicas mais comuns para identificar padrões sazonais em séries temporais é a análise de Fourier (*Fast Fourier Transform*). Este método transforma os dados do domínio do tempo para o domínio da frequência, permitindo a deteção de ciclos e padrões repetitivos em diferentes escalas temporais (Musbah *et al.*, 2019). Através da análise de Fourier, é possível transformar a informação relativa à sazonalidade em dados utilizáveis, facilitando previsões e análises de ciclos anuais e semestrais (Musbah *et al.*, 2019). Complementando esta abordagem, surgiu a técnica *Wavelet Transform*, que permite a análise da sazonalidade em múltiplas escalas temporais de forma simultânea (Tonkin *et al.*, 2017).

Outra ferramenta amplamente utilizada é o modelo ARIMA (*Autoregressive Integrated Moving Average*) que, quando ajustado para padrões sazonais, resulta no modelo SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Este modelo integra componentes sazonais no processo de previsão e é eficaz na captura de padrões sazonais complexos, sendo frequentemente aplicado em redes de fornecimento industrial, onde demonstra grande utilidade (Thornhill & Naim, 2006).

Adicionalmente, a decomposição STL (*Seasonal-Trend Decomposition using Loess*) é uma abordagem poderosa para a análise de séries temporais. Este método permite separar as séries em três componentes: tendência, sazonalidade e ruído. Através desta técnica, torna-se possível identificar e isolar os elementos sazonais, oferecendo uma visão clara das flutuações ao longo do tempo (Malindzakova *et al.*, 2024).

Nos dias de hoje, a análise de sazonalidade tem beneficiado de abordagens mais modernas com recurso ao machine learning. Por exemplo, os modelos *Long Short-Term Memory* (LSTM), baseados em redes neuronais, destacam-se pela sua capacidade de prever padrões sazonais complexos, capturando dependências temporais de longo prazo e oferecendo previsões robustas (Vishwanath *et al.*, 2024).

4.1.4.2.1. Google Trends como ferramenta de estudo das tendências sazonais

O *Google Trends* é uma ferramenta analítica poderosa que fornece informações sobre o volume de pesquisas de termos específicos na *Internet*. O valor mais alto de quota num período é normalizado para 100, enquanto o ponto inicial é normalizado para zero (Choi & Varian, 2012). As pesquisas são "amplamente correspondidas", ou seja, incluem variações relacionadas de termos e os dados são calculados por amostragem, podendo apresentar pequenas variações diárias (Choi & Varian, 2012). Desde o seu lançamento, tem sido amplamente utilizado para identificar padrões sazonais e tendências temporais em várias áreas, como *marketing*, comportamento do consumidor e economia (Chanthati, 2024).

Uma das formas de utilizar o *Google Trends* para estudar tendências sazonais é integrá-lo como variável exógena em modelos ARIMA, o que pode melhorar significativamente a precisão das previsões e reduzir o erro médio absoluto percentual (MAPE⁴). Esta abordagem é eficaz porque há frequentemente uma forte correlação entre os valores obtidos no *Google Trends* e os preços praticados nos produtos (Carta *et al.*, 2019). Assim, o *Google Trends* permite às empresas identificar rapidamente quais os produtos mais populares no mercado, com base nas palavras-chave pesquisadas no motor de pesquisa da Google, tornando-se um ponto de partida para prever mudanças futuras (Boone, 2016).

⁴ O erro percentual médio absoluto (MAPE) é uma medida de precisão que expressa a magnitude dos erros de previsão em termos percentuais, sendo amplamente utilizada para avaliar modelos de previsão (Hyndman & Koehler, 2006).

Além disso, ao oferecer *insights* valiosos sobre os padrões de comportamento dos consumidores, o *Google Trends* vai além do simples monitoramento, funcionando também como uma ferramenta preditiva poderosa. Esta funcionalidade permite que as marcas adaptem as suas estratégias com base nos resultados obtidos e com isso compreender possíveis comportamento no futuro (Choi & Varian, 2012; Jun *et al.*, 2018). Com isso, as empresas podem otimizar a alocação de recursos, reduzir desperdícios e planejar os *stocks* de forma mais eficiente (LaValle *et al.*, 2011). Desta forma, o *Google Trends* ajuda as empresas não apenas a analisar flutuações na procura, mas também a tomar decisões mais informadas e estratégicas relativamente ao *marketing* e à gestão de produtos (Hassani & Silva, 2015; Wedel & Kannan, 2016).

4.2. Metodologia

A metodologia é uma das secções mais cruciais de um artigo científico, pois descreve os métodos e os processos que serão usados para conduzir a investigação, garantindo a transparência e a replicabilidade (Creswell, 2009). Neste ponto, deve-se apresentar de forma clara e detalhada as etapas seguidas, incluindo a definição do problema, a abordagem escolhida, os instrumentos de recolha de dados, o desenho da amostra e as técnicas de análise de dados (Creswell, 2009).

Uma metodologia científica pode ser qualitativa, quantitativa ou mista, dependendo do objetivo do estudo. Neste caso em análise, a abordagem metodológica escolhida foi a quantitativa. Esta abordagem baseia-se na análise de dados numéricos, sendo utilizada para testar hipóteses ou medir relações entre variáveis (Bryman, 2016). Uma metodologia científica quantitativa caracteriza-se pela objetividade, rigor e sistematização, sendo frequentemente aplicada em estudos que visam generalizar resultados para populações mais amplas (Creswell, 2009).

A investigação quantitativa caracteriza-se pelo uso de instrumentos padronizados, como inquéritos estruturados, testes e bases de dados (Fowler, 2014). Estes garantem a consistência na medição, permitindo uma análise estatística rigorosa. Outra característica central é a objetividade, que constitui um princípio fundamental da investigação quantitativa, assumindo uma posição neutra, refletindo fielmente a realidade observada (Bryman, 2016).

Este rigor é alcançado através da aplicação de métodos estatísticos que reduzem a subjetividade na análise (Creswell, 2009).

A utilização de uma metodologia quantitativa distingue-se pela sua capacidade de generalizar os resultados, desde que sejam utilizadas amostras representativas e técnicas de amostragem adequadas (Babbie, 2013). Além disso, o recurso a métodos estatísticos rigorosos permite identificar padrões, medir relações entre variáveis e testar hipóteses com objetividade, contribuindo para a credibilidade científica dos resultados (Field, 2018). Contudo, esta abordagem apresenta algumas limitações, como a dificuldade em captar nuances e subjetividades, o que pode levar à simplificação de fenómenos complexos (Bryman, 2016). Adicionalmente, a dependência de variáveis mensuráveis e a rigidez dos instrumentos podem comprometer a validade interna em contextos mais dinâmicos (Neuman, 2014).

4.2.1. Hipótese

Os modelos que sejam capazes de combinar dados internos e externos são mais precisos no estudo de flutuações sazonais, podendo ajudar em vários aspetos como a gestão de inventário e as campanhas de *marketing* (Liashenko & Yakymchuk, 2023). Para além disso, a incorporação de dados externos aumenta a robustez das previsões, permitindo que as empresas adaptem rapidamente suas operações a mudanças de mercado (Sharma *et al.*, 2021). Com isso, a análise de dados desempenha um papel crucial neste contexto, pois permite interpretar grandes volumes de informação, integrando *insights* sobre o desempenho passado e as tendências emergentes do mercado (Chatfield, 1995a; Adrian *et al.*, 2018).

Ferramentas como o *Google Trends* têm-se mostrado particularmente eficazes na observação de tendências, funcionando como uma variável preditiva ou descritiva em modelos estatísticos. Estas ferramentas permitem identificar padrões de sazonalidade que, quando cruzados com dados internos, conseguem melhorar significativamente a previsão da procura (Choi & Varian, 2012; Hassani & Silva, 2015). Por exemplo, ao analisar simultaneamente as visualizações de produtos no *website* e os volumes de pesquisa externa, é possível ajustar campanhas de *marketing* e gerir os *stocks* de forma mais eficiente, maximizando as receitas em períodos de elevada procura (LaValle *et al.*, 2011).

Adicionalmente, a integração destes dados reforça a tomada de decisão ao reduzir incertezas e alinhar estratégias operacionais com os comportamentos dos consumidores (Davenport & Harris, 2007; Janssen *et al.*, 2017). As empresas que utilizam análises descritivas baseadas em múltiplas fontes de dados conseguem identificar padrões históricos e compreender o comportamento passado dos consumidores, o que pode apoiar decisões estratégicas, aumentando a sua competitividade no mercado (Chatfield, 1995a; Shumway & Stoffer, 2011). Portanto, para o estudo são propostas as seguintes hipóteses:

H0: A combinação de dados internos e externos permite identificar padrões sazonais de consumo em produtos para casa no mercado de e-commerce, facilitando o desenvolvimento das estratégias de marketing da entidade.

H1: A integração dos dados internos e externos não é eficaz na identificação de padrões sazonais de consumo em produtos para casa no mercado de e-commerce.

4.2.2. Amostra e recolha de dados

No que diz respeito à recolha de dados para o caso de estudo, foram utilizados dados secundários, ou seja, informações previamente reunidas por terceiros, que podem ser analisadas novamente para um propósito diferente do original (Bryman, 2016). Neste contexto, os dados foram obtidos a partir de duas fontes distintas: os dados externos foram extraídos do *Google Trends*, enquanto os dados internos foram recolhidos junto da empresa em análise, a La Redoute Portugal.

Além disso, a recolha de dados seguiu uma abordagem longitudinal, permitindo a medição repetida de variáveis numa amostra fixa ao longo do tempo (Bryman, 2016). Esta estratégia é particularmente vantajosa para examinar tendências, processos e efeitos a longo prazo, pois possibilita a documentação da evolução dos fenómenos ao longo do tempo, permitindo identificar relações causais com maior precisão, uma vez que acompanha a sequência de eventos e comportamentos (Creswell, 2009).

Relativamente à estratégia de investigação, foi adotada a abordagem *survey*. Esta metodologia é concebida para recolher dados padronizados de uma amostra representativa, com o objetivo de descrever ou explorar relações entre variáveis (Bryman, 2016). Através desta abordagem, é possível analisar tendências, atitudes, opiniões ou comportamentos de um grande grupo de indivíduos (Creswell, 2009).

Relativamente à amostra, o subconjunto da população selecionado para participar no estudo, a escolha foi feita com base em critérios que garantem a representatividade e minimizam possíveis enviesamentos, permitindo assim, a generalização dos resultados para a população em geral (Bryman, 2016). A recolha de dados decorreu num período específico, compreendido entre 1 de janeiro de 2023 e 28 de dezembro de 2024 (aproximadamente dois anos).

Para os dados internos, a amostra foi estratificada, dividindo a população em estratos com base em características relevantes para a investigação. Posteriormente, foi escolhida aleatoriamente uma amostra de cada grupo, garantindo a representatividade e maior precisão estatística, especialmente em populações heterogéneas (Bryman, 2016; Creswell, 2009). Este estudo focou-se nos clientes da La Redoute Portugal que compraram ou visualizaram produtos da categoria para casa no *website* da La Redoute Portugal.

Por outro lado, na recolha de dados externos, foi utilizada uma amostra intencional, baseada em critérios específicos. Este método envolve a seleção deliberada de indivíduos ou grupos com características pertinentes para os objetivos do estudo (Creswell, 2009). No caso do *Google Trends*, os dados foram recolhidos com base em palavras-chave previamente definidas pelo investigador, alinhadas com a categoria de produtos para casa.

4.2.3. Knowledge Discovery in Databases (KDD)

O KDD (*Knowledge Discovery in Databases*) concentra-se no desenvolvimento de métodos e técnicas que permitem compreender e interpretar dados complexos e volumosos, transformando-os em formatos mais acessíveis, como relatórios compactos, modelos descritivos ou modelos preditivos (Fayyad *et al.*, 1996). Estas ferramentas são particularmente importantes numa era em que o volume de dados excede a capacidade humana de análise manual, devido à abundância e à acessibilidade de dados na era digital (Maimon & Rokach, 2005).

No centro do processo do KDD está a *data mining*, que utiliza técnicas específicas para descobrir padrões relevantes e estruturados nos dados (Maimon & Rokach, 2005). Este campo interdisciplinar relaciona-se com áreas como a aprendizagem automática, estatística e as bases de dados, beneficiando do avanço de métodos computacionais para oferecer soluções que facilitem a compreensão e aplicação de dados na tomada de decisões (Norton, 1999).

A evolução do KDD resulta da interseção de várias áreas, como a aprendizagem automática, o reconhecimento de padrões, as bases de dados, a estatística, a inteligência artificial e a visualização de dados (Fayyad *et al.*, 1996). O seu objetivo principal é extrair conhecimento de alto nível a partir de grandes conjuntos de dados, identificando padrões compreensíveis e úteis (Fayyad *et al.*, 1996). Além disso, este processo visa também a criação de modelos preditivos que permitam antecipar resultados futuros com base em dados históricos (Maimon & Rokach, 2005). Embora se apoie em técnicas destas áreas para identificar padrões, o KDD distingue-se por abranger todo o processo de descoberta de conhecimento (Fayyad *et al.*, 1996).

A necessidade de utilizar um processo como o KDD surge do facto de o método tradicional de análise de dados, baseado na interpretação manual, se ter tornado impraticável devido ao crescimento exponencial do volume e da complexidade dos dados em diversas áreas (Fayyad *et al.*, 1996). Esta realidade torna essencial a automação da análise de dados, permitindo às organizações utilizar os dados para obter vantagens competitivas, melhorar a eficiência e compreender melhor o mundo (Fayyad *et al.*, 1996). O KDD é um processo interativo, composto por várias etapas, desde a compreensão do domínio até à implementação do conhecimento descoberto, sendo atualmente um processo cada vez mais essencial (Maimon & Rokach, 2005).

O KDD surge como uma solução para enfrentar a sobrecarga de dados, utilizando ferramentas computacionais avançadas para identificar padrões e transformar grandes volumes de dados em conhecimento útil de forma eficiente e escalável (Fayyad *et al.*, 1996). Este processo deve ter em consideração algumas características como:

- **Representação em Linguagens de Alto Nível:** O conhecimento descoberto deve ser representado numa linguagem compreensível para humanos ou utilizável por sistemas informáticos, como regras, redes causais ou representações gráficas (Frawley *et al.*, 1992).
- **Precisão:** As descobertas devem refletir com precisão o conteúdo da base de dados e em caso de incerteza associada a um padrão, a mesma deve ser claramente comunicada, considerando fatores como a integridade dos dados e o tamanho da amostra (Frawley *et al.*, 1992).

- **Resultados interessantes:** Os padrões descobertos devem ser novos, úteis e não triviais (o processo de descoberta vai além de cálculos simples, envolvendo criatividade e autonomia no processamento dos dados), em que a sua utilidade implica que o conhecimento pode ajudar a alcançar os objetivos do utilizador ou do sistema (Frawley *et al.*, 1992).
- **Eficiência:** O processo de descoberta deve ser eficiente, ou seja, escalável para lidar com bases de dados de grandes dimensões, onde os algoritmos devem ser projetados para serem rápidos e consumir recursos de forma previsível e aceitável (Frawley *et al.*, 1992).

4.2.3.1. Conceito

Historicamente, a procura por padrões úteis em dados recebeu diferentes designações, como mineração de dados, extração de conhecimento, descoberta de informação e arqueologia de dados (Fayyad *et al.*, 1996). No entanto, o termo "*Knowledge Discovery in Databases*" foi introduzido mais tarde, em 1989, destacando-se o seu objetivo principal: extrair conhecimento útil a partir de dados (Piatetsky-Shapiro, 1991).



Figura 3 - Visão geral dos passos do processo de KDD. Adaptado de: Fayyad *et al.*, 1996

O KDD (Figura 3) é entendido como um processo abrangente que engloba várias etapas, enquanto por exemplo, a *data mining* é apenas um passo específico dentro desse processo, focado na aplicação de algoritmos para identificar padrões (Norton, 1999). Contudo, apesar de ser apenas uma das etapas, a *data mining* acaba por ter um papel central, pois envolve a utilização de algoritmos capazes de explorar os dados, desenvolver modelos e, com isso, descobrir padrões previamente desconhecidos (Maimon & Rokach, 2005). Outras etapas essenciais incluem preparação, seleção, limpeza dos dados, uso de conhecimento prévio e interpretação dos resultados (Fayyad *et al.*, 1996).

O KDD é o processo de identificar padrões válidos, novos, úteis e compreensíveis nos dados. Os dados representam factos ou casos numa base de dados, e os padrões descrevem subconjuntos ou modelos aplicáveis a esses dados (Norton, 1999). O processo de KDD envolve várias etapas, como preparação dos dados, procura de padrões, avaliação e refinamento, repetidas em múltiplas iterações (Fayyad *et al.*, 1996).

Os padrões descobertos devem ser válidos em novos dados, novos para o sistema (idealmente para o utilizador), úteis e compreensíveis (Fayyad *et al.*, 1996). A validade e utilidade podem ser medidas quantitativamente, mas a novidade e a compreensibilidade são mais subjetivas. A simplicidade de um padrão pode ser usada como uma forma de medir a sua compreensibilidade (Fayyad *et al.*, 1996).

O conceito de interesse combina critérios como validade, novidade, utilidade e simplicidade para avaliar o valor geral de um padrão (Silberschatz & Tuzhilin, 1995; Piatetsky-Shapiro & Matheus, 1994). Funções de interesse podem ser definidas explicitamente ou manifestadas implicitamente por meio de uma ordenação dos padrões ou modelos descobertos pelo sistema de KDD (Fayyad *et al.*, 1996). Um padrão é considerado conhecimento se exceder um limiar de interesse, determinado pelo utilizador e pelo domínio específico (Fayyad *et al.*, 1996).

4.2.3.2. Data Mining

A *data mining* é utilizada no estudo de bases de dados para extrair padrões e informações úteis a partir de grandes volumes de dados (García *et al.*, 2015). Este processo assume um papel fundamental, pois permite transformar dados brutos em conhecimento valioso, auxiliando a tomada de decisões em diversas áreas (Han *et al.*, 2012).

Trata-se de um processo interdisciplinar que combina estatística, inteligência artificial, aprendizagem automática e análise de bases de dados para identificar padrões, relações e anomalias previamente desconhecidas (Hand, 1998; Witten *et al.*, 2011). A *data mining* destaca-se também pela sua capacidade de explorar dados complexos, fornecendo *insights* que contribuem para a melhoria de processos e estratégias em diferentes contextos (Romero & Ventura, 2013).

A integração da *data mining* nos sistemas de suporte à decisão faz dela uma ferramenta avançada dentro das Tecnologias de Informação⁵, operando em três camadas principais: fontes de dados (bases operacionais, dados estruturados e não estruturados), *data warehouses* e Online Analytical Processing (OLAP), que facilitam a análise multinível, e ferramentas analíticas, onde a *data mining* permite descobrir padrões complexos e realizar previsões (Maimon & Rokach, 2005). Este processo torna o pré-processamento de dados mais eficiente, reduzindo o tempo necessário para a preparação das bases de dados. No entanto, devido à sua complexidade, exige competências especializadas para ser corretamente implementado (Maimon & Rokach, 2005).

A *data mining* insere-se no contexto da descoberta de conhecimento em bases de dados (KDD), cujo objetivo é transformar dados brutos em informações interpretáveis e acionáveis. Esta abordagem possibilita a identificação de tendências, estruturas subjacentes e comportamentos que suportam a tomada de decisões em várias áreas (Han *et al.*, 2012). Tanto o KDD como a *data mining* têm vindo a despertar grande interesse, impulsionados pelo crescimento exponencial dos volumes de dados digitais. Esta realidade tem gerado uma necessidade urgente de novas ferramentas e metodologias computacionais que permitam processar e extrair informações relevantes de grandes quantidades de dados (Fayyad *et al.*, 1996).

4.2.3.3. Variáveis

- Variável dependente: Identificação de padrões sazonais de consumo em produtos para casa no mercado de e-commerce.

A variável dependente tem a capacidade de medir e identificar padrões sazonais no consumo de produtos para casa, analisando se os dados internos e externos utilizados revelam tendências recorrentes ao longo do tempo. Esta análise de padrões sazonais permite identificar e antecipar períodos de maior ou menor procura, no comportamento do consumidor, sendo essencial para estratégias de planeamento comercial (Chatfield, 1995a; Makridakis *et al.*, 1984). Assim, esta variável avalia a regularidade e a intensidade das variações sazonais no mercado digital.

⁵ Tecnologias de Informação é o conjunto de *hardware*, *software*, redes e sistemas utilizados para criar, processar, armazenar e disseminar informações em organizações, com o objetivo de melhorar a tomada de decisão, a coordenação e o controlo de operações (Laudon & Laudon, 2020).

A identificação de padrões sazonais foi analisada através da correlação de Pearson (r) entre os dados externos (*Google Trends*) e os dados internos (visualizações no *website*), de modo a assumir a recorrência de certos padrões ao longo do tempo, refletindo-se na sazonalidade. De referir neste caso que nos dados internos não foi considerado os dados dos lucros pois, neste caso foi feita a comparação só em termos de pesquisa, quer internamente quer externamente.

$$r = \frac{\sum(X - \bar{X})(Y - \bar{Y})}{\sqrt{\sum(X - \bar{X})^2} \sqrt{\sum(Y - \bar{Y})^2}}$$

Onde:

- X → Média das visualizações dos produtos no *website* (dados internos).
- Y → Média do *Google Trends* (dados externos).
- \bar{X}, \bar{Y} → Médias dos respetivos valores.

É utilizado o método da correlação de Pearson pois, é um método amplamente utilizado na análise de padrões sazonais, em que o mesmo permite verificar se há uma relação linear entre diferentes fontes de dados ao longo do tempo (Chatfield, 1995b). Neste caso, em contexto do *e-commerce*, correlação entre diferentes fontes de dados pode indicar a consistência de padrões sazonais (Makridakis *et al.*, 1984).

Neste estudo, a correlação de Pearson foi realizada através do programa *Excel*, através do comando (=CORREL), em que todos os valores dos dados estão dentro da mesma escala, onde foi feita uma ponderação média, para que se pudesse ser feito o cálculo da correlação de Pearson.

Os dados que serão recolhidos poderão significar diversas coisas, conforme o valor a que se chegou, ou seja, dependendo do valor, o mesmo pode estar em diferentes níveis da escala do coeficiente de Pearson (Callegari-Jacques, 2003):

- $|r| > 0.7$ → Correlação forte → Os padrões sazonais das duas fontes de dados estão alinhados e são identificáveis;
- $0.4 < |r| \leq 0.7$ → Correlação moderada → Existe alguma relação, mas pode variar;
- $|r| \leq 0.4$ → Correlação fraca ou inexistente → Os padrões sazonais não são consistentes.

Assim sendo, a unidade de medida nesta variável será o índice de correlação (r), onde o mesmo varia entre 1 e -1, onde:

- 1 → Correlação perfeita positiva (quando um aumenta, o outro também aumenta);
- 0 → Ausência de correlação;
- -1 → Correlação perfeita negativa (quando um aumenta, o outro diminui).

Os dados utilizados nesta variável têm origem em duas fontes distintas, uma interna que vai corresponder às visualizações do tipo de produto no *website* e, uma fonte externa que corresponde à procura global do produto, em que os dados são dados através do Google Trends, através do número de pesquisas feito no motor de pesquisa da Google.

Esta hipótese propõe que o uso de dados internos e externos permite identificar padrões sazonais e mais especificamente, mede se os padrões sazonais identificados internamente (Visualizações) correspondem às tendências gerais do mercado (*Google Trends*), medindo a existência desses padrões ao analisar a consistência dos dados ao longo do tempo (Makridakis et al., 1984).

É utilizado um método quantitativo reconhecido para avaliar o alinhamento entre as fontes de dados, como é a correlação de Pearson, e a partir deste método podemos verificar se os padrões sazonais identificados nos dados externos (*Google Trends*) correspondem ao comportamento real do consumidor no *website* da La Redoute Portugal (Chatfield, 1995b). Ajuda a perceber se os padrões sazonais podem ser apenas identificados a partir dos dados internos, ou se os dados externos ajudam a trazer valor adicional, sendo este método um dos pilares das metodologias de *data mining* e *business intelligence* (Han et al., 2012).

- Variável Independente: Uso de dados internos e externos numa análise sazonal

Esta variável vai representar a combinação de dados internos e externos utilizados para identificar padrões sazonais de consumo em produtos para casa no mercado de e-commerce. A integração de múltiplas fontes fortalece a análise, num contexto de *data mining*, permitindo capturar padrões mais complexos e assim reduzir a incerteza (Han et al., 2012).

Além disso, a interação entre esses dados, internos e externos, oferece uma visão mais completa do comportamento do consumidor fornecendo uma visão mais abrangente da dinâmica do consumidor no mercado digital (Nalchigar & Weber, 2012).

- Os dados internos refletem o comportamento real dos consumidores dentro da plataforma da empresa, captando interesse (visualizações) e conversões (lucro);
- Os dados externos representam a intenção de pesquisa e procura geral pelos produtos analisados, refletindo tendências globais no *Google Trends* antes de serem convertidas em visitas e compras na loja online.

Esta variável foi construída a partir da média ponderada das três fontes de dados que compõem o mapa de sazonalidade, de forma a garantir que todos se encontram na mesma escala, de modo a evitar distorções na análise comparativa (Nalchigar & Weber, 2012). A mesma foi construída com base numa média dos dados obtidos em 2023 e 2024, divididos por quinzenas, garantindo uma análise mais estável e minimizando oscilações atípicas (Han *et al.*, 2012). Uma análise feita em períodos mais fixos, como quinzenas, pode melhorar a identificação de padrões sazonais, pois reduz o impacto de flutuações diárias ou semanais que poderiam enviesar na interpretação dos dados (Bertsimas & Kallus, 2019).

- Dados externos - *Google Trends* → Representa a popularidade do termo de pesquisa ao longo do tempo;
- Dados internos – Visualizações e o lucro realizado por tipo de produto → Dados que representam o tráfego no *website* e o rendimento obtido pelo tipo de produto.

Assim sendo, a unidade de medida desta variável será uma ponderação média dos valores recolhidos dos dados internos e externos, em que foi feita a seguinte conta:

$$\left(\frac{\text{Valor Antigo do Produto (VA)}}{\text{Valor Médio do Produto (VMP)}} \right) \times 100$$

Ou seja, a partir desta conta consegue-se ter uma escala igual para todos os dados e a mesma consegue-nos dizer o que é que o novo valor corresponde.

- Valor acima de 100 corresponde a um valor que se encontra acima da média;
- Valor abaixo de 100 corresponde a um valor que se encontra abaixo da média.

Por fim, a variável independente foi construída a partir da média ponderada das três fontes de dados que compõem o mapa de sazonalidade. Cada componente tem um peso previamente definido:

Uso dados internos e externos

$$= (\text{Google Trends} \times 60\%) + (\text{Visualizações(PDP Views)} \times 25\%) \\ + (\text{Lucro(DAD)} \times 15\%)$$

Esta média ponderada foi realizada através de uma discussão interna na empresa para se chegar à percentagem ideal para cada dado. No entanto teve-se em consideração em que esta média ponderada seguisse os princípios de *data mining* e de uma análise descritiva, permitindo que fosse possível fazer uma comparação eficaz entre fontes de dados distintas (Han *et al.*, 2012).

Existem duas fontes para os dados recolhidos e os mesmos eram recolhidos quinzenalmente, seguindo a estrutura do mapa de sazonalidade.

- Dados internos: Visualizações dos produtos no *website* e lucros da empresa com o tipo de produto (Extraídos da plataforma interna da empresa);
- Dados externos: Índice de *Google Trends* para os produtos analisados.

A hipótese sugere que a combinação de dados internos e externos ajuda a identificar padrões sazonais de consumo. Esta variável mede precisamente o impacto desses dados na análise da sazonalidade, aliando-as com a importância de cruzar fontes internas e externas para melhorar a análise de tendências de consumo (Han *et al.*, 2012).

Capta diferentes dimensões do comportamento do consumidor, onde os dados internos captam o tráfego e as vendas reais, ou seja, o comportamento dentro do *website*, enquanto os dados externos captam a intenção de compra antes do consumidor visitar o *website*, dados esses que demonstram que em muitos casos é possível antecipar os padrões de consumo online, e neste caso, identificar os períodos sazonais de maior e menor procura (Nalchigar & Weber, 2012).

Permite em caso de ambas as variáveis consigam apresentar valores positivos, isto é, caso exista uma boa correlação entre os dados internos e externos, a sazonalidade que seja identificada vai corresponder a uma sazonalidade verdadeira, ou seja, que se verifica nos dois tipos de dados, internos e externos, que foram recolhidos para o estudo o que quer dizer que se consegue identificar bem quais vão ser os melhores e piores períodos para determinado produto. A partir destes períodos identificados, a organização, que neste caso será a La Redoute Portugal, consegue ter uma melhor ideia dos comportamentos de compra por parte dos consumidores e a partir daí, utilizar os dados para desenvolver uma estratégia que vá de encontro às suas necessidades.

4.2.3.4. Procedimento

O processo de Knowledge Discovery in Databases (**Figura 3**) é uma metodologia sistemática e iterativa que tem como objetivo transformar grandes volumes de dados em conhecimento útil e compreensível (Maimon & Rokach, 2005). Este processo é composto por várias etapas, desde a compreensão do domínio da aplicação até à utilização prática do conhecimento descoberto, incluindo tarefas como seleção, limpeza, transformação de dados, mineração e avaliação de padrões (Fayyad *et al.*, 1996). A eficácia do processo de KDD reside na sua capacidade de combinar métodos computacionais robustos com o conhecimento do domínio, permitindo extrair *insights* que apoiam a tomada de decisões em contextos reais. Além disso, este processo desempenha um papel fundamental na gestão da sobrecarga de dados na era digital, facilitando a identificação de informações relevantes e acionáveis (Aggarwal, 2015).

4.2.3.4.1. Compreensão do Domínio da Aplicação

O processo de KDD começa em alinhar o processo aos objetivos específicos. É nesta fase que se vai estabelecer contexto do problema, identificando as necessidades e os objetivos a serem atingidos, para que sejam tratados com grande clareza (Fayyad *et al.*, 1996). É também nesta etapa que se analisa as limitações e oportunidades dos dados disponíveis, além de integrar o conhecimento prévio do domínio, ajustando as expectativas e as metas conforme os resultados intermediários vão sendo obtidos (Maimon & Rokach, 2005).

Neste estudo, o objetivo principal é analisar as tendências sazonais de consumo de produtos para casa no mercado de *e-commerce*, recorrendo a dados internos e externos. Como a sazonalidade na maioria destes produtos não é claramente definida, o objetivo é identificar os períodos de maior procura, ajudando a La Redoute Portugal a comercializar os seus produtos nos momentos mais adequados. Esta abordagem permite compreender um pouco melhor tanto o comportamento de pesquisa como o de compra dos consumidores, integrando também informações de potenciais clientes fora do universo da empresa, o que pode trazer novos *insights* sobre os padrões de consumo neste mercado.

Desde o início do estudo, identificou-se uma limitação relevante: a combinação de dados internos e externos. Por um lado, os dados internos pertencem à La Redoute Portugal; por outro, os dados externos são provenientes da *Google*. A junção destas duas fontes de informação permitirá chegar a conclusões sobre os padrões de consumo de produtos para casa no mercado de *e-commerce*.

No entanto, a recolha de dados externos apresenta algumas restrições. Estes são obtidos através da plataforma *Google Trends*, que fornece uma escala de 0 a 100 para o número de pesquisas realizadas num determinado período, sem disponibilizar valores exatos. Além disso, palavras-chave com um número reduzido de pesquisas podem não ser contabilizadas, o que pode levar à exclusão de alguns produtos e enviesar, de certa forma, os resultados obtidos.

Outra limitação do estudo prende-se com a ambiguidade de certas palavras-chave. Em alguns casos, uma mesma palavra pode ter vários significados, o que pode levar a resultados distorcidos, incluindo dados de pesquisas que não são relevantes para a análise em questão.

4.2.3.4.2. Seleção dos Dados

O passo seguinte do processo de KDD consiste na seleção dos dados a utilizar, sendo esta uma fase crítica, pois é aqui que se estabelece a base para toda a descoberta de conhecimento.

O foco deve estar nos subconjuntos de dados ou variáveis mais relevantes para os objetivos do estudo, incluindo a análise de dados já disponíveis e, se necessário, a integração de novas fontes (Fayyad *et al.*, 1996). A seleção criteriosa dos dados é essencial para evitar desvios, uma vez que a negligência de atributos importantes pode comprometer todo o processo (Maimon & Rokach, 2005).

Além disso, deve-se garantir um equilíbrio entre a complexidade dos dados recolhidos e a necessidade de incluir o máximo de informações relevantes (Maimon & Rokach, 2005).

Neste estudo, foram selecionados dois tipos de dados: internos e externos. A combinação destes dois tipos permite captar tanto o comportamento real dos consumidores dentro da plataforma da empresa, neste caso, no *website* da La Redoute Portugal, como também o interesse mais amplo do mercado, proporcionando uma visão mais abrangente das tendências sazonais.

Relativamente aos dados externos, estes foram recolhidos a partir do *Google Trends*, considerando apenas palavras-chave que contivessem pelo menos alguma informação relevante para o estudo. Estes dados refletem o volume de pesquisas associadas aos produtos analisados, funcionando como um indicador do interesse do público ao longo do tempo, abrangendo os anos de 2023 e 2024.

Por outro lado, os dados internos incluem informações sobre as receitas geradas pelos produtos (lucros), designadas nos dados da empresa como *DAD*, bem como o número de visualizações dos produtos no *website* da empresa, designadas como *PDP Views*. Estes dados internos oferecem um registo detalhado da interação dos consumidores com os produtos dentro da plataforma da La Redoute Portugal, permitindo uma análise mais aprofundada do comportamento de compra.

4.2.3.4.3. Limpeza e Pré-processamento dos Dados

A etapa de limpeza e pré-processamento é reconhecida como uma das mais demoradas e críticas, pois é essencial para a remoção de ruído e correção de inconsistências nos dados (Fayyad *et al.*, 1996). A qualidade do conjunto de dados nesta fase tem um impacto direto na validade dos padrões descobertos (Fayyad *et al.*, 1996). Durante este processo, pode ocorrer a deteção de *outliers*, ou seja, valores extremos que podem distorcer os resultados da análise (Han *et al.*, 2012). Além disso, nesta fase também se pode recorrer a algoritmos de mineração de dados para preencher lacunas ou prever valores ausentes (Maimon & Rokach, 2005).

Nesta etapa, foi essencial a criação de novos valores, gerados a partir da média dos valores retirados, tanto dos dados externos como dos dados internos. Estes novos valores foram calculados individualmente, mas seguindo o mesmo processo.

A fórmula utilizada foi:

$$\left(\frac{\text{Valor Antigo do Produto (VA)}}{\text{Valor Médio do Produto (VMP)}} \right) \times 100$$

Com esta abordagem, foi possível obter uma noção clara da posição de cada valor relativamente à média. Assim, se o resultado fosse superior a 100, significava que o valor estava acima da média; se fosse inferior a 100, indicava que estava abaixo da média.

Estes novos valores, designados no estudo como Índice, permitiram uniformizar os dados, garantindo que pudessem ser combinados ou comparados futuramente para a análise. O processo de normalização das escalas revelou-se crucial, especialmente porque os dados externos, extraídos do *Google Trends*, estavam representados numa escala de 0 a 100, ao contrário dos dados internos, que se encontravam em valores absolutos.

No que diz respeito aos valores ausentes, o problema manifestou-se sobretudo na recolha dos dados externos, uma vez que os valores fornecidos pelo *Google Trends* estavam numa escala relativa de 0 a 100. E, devido à natureza desta escala, verificou-se que o tratamento desses valores ausentes não seria viável para o estudo, pois poderia introduzir perturbações nos resultados finais.

4.2.3.4.4. Transformação dos Dados

Nesta fase, o principal objetivo é melhorar a representatividade dos dados para o processo de mineração, recorrendo a diversas técnicas, como a eliminação de variáveis redundantes ou irrelevantes e a conversão de variáveis contínuas em categorias (Fayyad *et al.*, 1996). Este passo pode incluir a redução da dimensionalidade e a extração de atributos relevantes, sendo a transformação dos dados muitas vezes altamente específica ao domínio em estudo (Aggarwal, 2015; Maimon & Rokach, 2005).

Com base no Índice previamente criado para a normalização das escalas, foi gerado um novo Índice, denominado Índice Final. Este novo índice consistiu na agregação de todos os índices dos produtos pertencentes a uma mesma categoria, sendo o seu cálculo ponderado com base na importância relativa de cada produto dentro da categoria. A percentagem atribuída a cada produto foi determinada pela seguinte fórmula:

$$\left(\frac{\text{Valor Médio do Produto (VMP)}}{\text{Soma dos Valores Médios dos Produtos}} \right) \times 100$$

Através deste cálculo, foi possível identificar o peso relativo de cada produto na sua respetiva categoria. No caso dos dados recolhidos do *Google Trends*, o Valor Médio do Produto foi obtido diretamente na plataforma da Google, juntando todas as palavras-chave relacionadas. Como os valores fornecidos pelo *Google Trends* são apresentados numa escala relativa, este método foi necessário para garantir que o Índice Final refletisse corretamente a representatividade de cada produto dentro da família de produtos correspondente.

Nesta fase, também foi realizada uma conversão temporal dos dados. Os dados recolhidos semanalmente foram reorganizados em períodos quinzenais. Embora uma análise semanal pudesse oferecer maior granularidade, a conversão para períodos quinzenais permitiu uma visão mais clara das tendências ao longo de um mês, facilitando a análise da sazonalidade. Além disso, optar por períodos quinzenais em vez de períodos mensais permitiu manter um nível de detalhe que ajuda a compreender melhor as flutuações dentro de cada mês.

4.2.3.4.5. Data Mining

Esta etapa do processo de KDD, denominada *data mining*, consiste na aplicação de um conjunto de técnicas e algoritmos para extrair padrões significativos, abrangendo três aspetos fundamentais: a definição da tarefa de mineração, a escolha do algoritmo mais adequado e a execução do processo de descoberta de conhecimento. O processo inicia-se com a definição da tarefa de *data mining*, determinando se será uma tarefa preditiva, como classificação ou regressão, ou uma tarefa descritiva, como *clustering* ou regras de associação (Fayyad *et al.*, 1996). A escolha depende diretamente dos objetivos estabelecidos no início do estudo, garantindo que os resultados sejam interpretáveis e claros (Witten *et al.*, 2011).

De seguida, procede-se à seleção dos algoritmos a utilizar, tendo em conta um equilíbrio entre precisão e eficiência (Fayyad *et al.*, 1996). No presente estudo, foram utilizadas técnicas de agregação de dados ponderada, um método comum em *data mining* para combinar múltiplas fontes de informação e gerar um único indicador representativo. Esta abordagem foi escolhida por dispensar modelos estatísticos complexos e permitir uma análise mais facilmente interpretável (Han *et al.*, 2012).

A média ponderada revelou-se uma solução eficaz para integrar múltiplas fontes de dados com relevâncias distintas, garantindo que a importância relativa de cada variável fosse refletida de forma adequada.

Métodos heurísticos, como a média ponderada, são muitas vezes mais apropriados do que algoritmos sofisticados de *machine learning*, especialmente quando a interoperabilidade é um fator-chave na tomada de decisões (Witten *et al.*, 2011).

Na última fase, a execução da *data mining* ocorre em quatro passos principais: (1) aplicação dos modelos selecionados aos dados preparados; (2) geração dos resultados iniciais e ajuste de parâmetros, caso necessário; (3) interpretação dos padrões extraídos e (4); representação dos resultados de forma compreensível para os decisores (Han *et al.*, 2012). Para facilitar a interpretação dos padrões ocultos nos dados, pode ser utilizada a visualização de dados, como o conceito de *Visual Information Seeking Mantra*, que defende a criação de representações visuais para facilitar a exploração e compreensão dos dados (Shneiderman, 1996).

Neste caso, o trabalho baseia-se numa tarefa descritiva, pois o objetivo principal passa por identificar padrões sazonais nas categorias de produtos para casa ao longo de dois anos. Também, ao ser criado um mapa com os valores onde o mesmo, através de cores nos vai permitir perceber quais os melhores e piores períodos, o mapa consegue transformar dados complexos em informação visual e compreensível.

O algoritmo utilizado para a construção do mapa de sazonalidade baseou-se em modelos heurísticos de agregação e normalização. Foram atribuídos pesos específicos às três fontes de dados analisadas:

- *Google Trends*: 60%
- Visualizações de produtos no *website* (*PDP Views*): 25%
- Lucros obtidos pelos produtos (*DAD*): 15%

A distribuição dos pesos foi definida internamente na empresa, com base nos objetivos do estudo. O foco principal foi atribuir maior importância aos dados externos (*Google Trends*), uma vez que o objetivo era compreender o comportamento do consumidor externo, e não apenas dos clientes internos da La Redoute Portugal.

Assim, os dados do *Google Trends* representaram mais de metade do peso total (60%). Os restantes 40% foram divididos entre os dados internos, atribuindo-se maior peso às *PDP Views* (25%) em relação aos dados de lucros (*DAD*) (15%).

Esta decisão deve-se ao facto de o estudo estar mais orientado para identificar padrões de procura do que padrões de compra. Para minimizar o impacto de oscilações momentâneas nos dados, foi calculada a média dos valores de 2023 e 2024, conferindo maior robustez à análise.

O resultado final foi um mapa de sazonalidade, consolidando as três fontes de dados numa única métrica ponderada. Através de uma formatação condicional no *Excel*, com uma escala de cores (verde para os valores elevados, vermelho para os valores baixos e amarelo para o percentil 50), foi possível transformar os valores brutos em padrões visuais intuitivos, criando assim um mapa de calor. A divisão temporal quinzenal permitiu uma granularidade mais astuta na análise, oferecendo uma perceção mais clara da sazonalidade do mercado. Desta forma, os padrões descobertos tornaram-se compreensíveis e úteis para a tomada de decisões estratégicas.

4.2.3.4.6. Avaliação e Interpretação dos Resultados

Na etapa de avaliação e interpretação dos resultados no processo de KDD, é fundamental garantir que os padrões descobertos são válidos, úteis e compreensíveis. Isso implica analisar criticamente os padrões extraídos para determinar se representam conhecimento significativo ou se necessitam de refinamento (Fayyad *et al.*, 1996). A avaliação pode ser conduzida através de métricas quantitativas e qualitativas, garantindo que (Maimon & Rokach, 2005):

- A informação é estatisticamente significativa e pode ser aplicada a novos dados;
- Os padrões descobertos fornecem *insights* não previamente conhecidos;
- Os resultados são aplicáveis para suportar a tomada de decisão;
- Os padrões são compreensíveis e acionáveis.

A interpretação dos padrões envolve a compreensão do significado dos resultados e a determinação da sua aplicabilidade. Este processo pode exigir iterações adicionais, como a reformulação do problema ou ajustes nos parâmetros da análise (Fayyad *et al.*, 1996). Técnicas de visualização de dados, como gráficos, tabelas e mapas de calor, são frequentemente utilizadas para facilitar essa interpretação (Maimon & Rokach, 2005).

No presente estudo, o mapa de sazonalidade foi construído com base em dados reais provenientes de três fontes distintas (*Google Trends*, *PDP Views* e *DAD*). A combinação de dados internos e externos contribui para a validação dos padrões descobertos, reduzindo o risco de enviesamento dos dados (Han *et al.*, 2012). Além disso, os padrões identificados podem ser aplicados diretamente à estratégia comercial da empresa, alinhando-se com o princípio de *interestingness*⁶ dos padrões descobertos (Piatetsky-Shapiro & Matheus, 1994). A formatação condicional aplicada no *Excel*, utilizando uma escala de cores, torna os padrões intuitivos e fáceis de interpretar, permitindo que os decisores extraiam *insights* de forma rápida e eficaz.

A análise do mapa de sazonalidade permite:

- Identificar picos e quedas na procura para cada categoria de produtos;
- Avaliar se todas as categorias seguem o mesmo padrão sazonal ou se apresentam variações distintas;
- Compreender tendências sazonais e antecipar períodos de maior ou menor procura.

Desta forma, o estudo fornece uma visão clara e estruturada dos padrões de consumo, auxiliando a empresa na definição de estratégias comerciais mais eficazes.

4.2.3.4.7. Aplicação do Conhecimento Descoberto

Na última etapa do processo de KDD, os padrões descobertos são transformados em ações práticas, permitindo que a informação obtida seja utilizada para suportar decisões organizacionais, otimizar processos e melhorar estratégias empresariais (Brachman & Anand, 1996). Esta fase é essencial, pois a eficácia do processo de descoberta de conhecimento depende diretamente da sua aplicação prática (Maimon & Rokach, 2005).

No contexto do estudo e do mapa de sazonalidade, a La Redoute Portugal pode potenciar os *insights* obtidos de várias formas, nomeadamente:

⁶ *Interestingness* em *data mining* refere-se ao grau de utilidade, novidade, validade e compreensibilidade dos padrões descobertos, garantindo que sejam estatisticamente significativos, interpretáveis e aplicáveis na tomada de decisão (Piatetsky-Shapiro & Matheus, 1994).

1. Otimização das campanhas de *marketing*
 - Antecipação de tendências sazonais para ajustar a estratégia de comunicação.
 - Destaque de produtos sazonais no *website*, através de *banners* ou coleções temáticas.
 - Personalização das campanhas de e-mail *marketing*, promovendo produtos com maior procura no momento certo.
 - Planeamento de campanhas pagas (*Google Ads, Facebook Ads, Instagram Ads*) alinhadas com os períodos de maior interesse do consumidor.

2. Melhoria da experiência do utilizador no *website* e na *app*
 - Implementação de recomendações personalizadas, sugerindo produtos em alta conforme os padrões identificados.
 - Criação de páginas especiais com coleções sazonais, facilitando a navegação do consumidor.

3. Otimização de preços e promoções
 - Definição de estratégias de preços dinâmicos, maximizando margens de lucro durante períodos de elevada procura.
 - Criação de promoções estratégicas em períodos de menor interesse, estimulando a compra e reduzindo stocks parados.

A aplicação do mapa de sazonalidade permite, assim, que a empresa alavanque os padrões identificados para aprimorar as suas estratégias comerciais, garantindo maior eficiência e competitividade no mercado.

4.3.Resultados

A partir da análise dos dados no mapa de sazonalidade, foi possível identificar padrões de consumo produtos para casa no mercado de *e-commerce*, no qual verificamos que para cada tipo de produtos vai estar atribuída um padrão de sazonalidade diferente. Através da combinação de dados internos, como as visualizações no *website* e o lucro dos produtos, com dados externos provenientes do *Google Trends*, foi possível compreender a evolução da procura ao longo do tempo.

Os resultados revelaram períodos de maior e menor interesse pelos diferentes tipos de produtos, evidenciando tendências sazonais que podem ser utilizadas de diversas maneiras, de modo a implementar mais eficazmente a estratégia, neste caso, da La Redoute Portugal.

Além disso, a correlação entre os dados internos e externos demonstrou a importância da integração destas duas fontes de informação na identificação dos ciclos de consumo, reforçando a importância de abordagens baseadas em dados para a tomada de decisão no *e-commerce*.

De referir que na construção do mapa de sazonalidade (**Anexo A**), que foi realizada no programa de *Excel*, os resultados a que se chegou foi uma média dos dados dos dois anos do estudo, 2023 e 2024, onde o cálculo que foi feito para se chegar ao valor que foi utilizado no estudo do mapa foi o seguinte:

Uso dados internos e externos

$$= (\text{Google Trends} \times 60\%) + (\text{Visualizações}(PDP \text{ Views}) \times 25\%) + (\text{Lucro}(DAD) \times 15\%)$$

Também de forma a validar o período de sazonalidade que foi encontrado para cada família de produtos, o mesmo será validado através de uma correlação de Pearson, onde dentro do mesmo período vão ser comparados os dados do mapa de sazonalidade do *Google Trends* (**Anexo B**), em que consta apenas a média dos dados do *Google Trends* e os dados do mapa de sazonalidade das visualizações (*PDP Views*) (**Anexo C**), em que consta apenas a média dos dados das visualizações dos produtos no *website* da La Redoute Portugal. Esta correlação de Pearson é feita no programa *Excel* através do comando (= CORREL).

Com isto, os dados a que se chegaram foram os seguintes. Na família dos Sofás, onde foram considerados para o estudo sofás e poltronas, os valores no mapa de sazonalidade estão apresentados na Figura 4.

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Sofás	107	108	106	103	96	91	91	85	89	86	80	84
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	89	87	87	102	99	103	120	122	129	146	101	79

Figura 4 - Mapa de Sazonalidade (Sofás). Elaboração própria feita em *Excel*

Na validação desta família, é analisado o valor da correlação à que a mesma corresponde, sendo neste caso de 0,8 (**Tabela 6**). Com isto verifica-se que, de acordo com o índice de correlação, a correlação de Pearson que temos na família dos Sofás é uma correlação forte. Isto quer dizer que o mapa de sazonalidade apresenta dados que correspondem ao que se encontra internamente e externamente.

Verificamos que o principal período de procura por este tipo de produtos acontece nos meses de outubro e novembro, sendo esta mais forte no mês de novembro. Também encontramos um período bom no início do ano, nos meses de janeiro e fevereiro. Por outro lado, verificamos que o período de menor procura vai ser sobretudo, entre o final do mês de março indo até meados de agosto.

Família	Correlação de Pearson
Sofás	0,80

Tabela 6 - Correlação de Pearson da família dos Sofás. Elaboração própria com base em *outputs* do Excel

Na família do Mobiliário de Casa de Banho, onde foram considerados para estudo os móveis de casa de banho, espelhos de casa de banho e cesto de roupa suja, chegou-se aos valores abaixo (**Figura 5**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Mob. Casa Banho	115	107	100	92	85	92	86	82	85	75	94	87
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	110	94	90	99	107	118	123	113	135	140	103	53

Figura 5 - Mapa de Sazonalidade (Mobiliário de Casa de Banho). Elaboração própria feita em Excel

A validação da sazonalidade desta família, foi elaborada uma correlação de Pearson, de onde se obteve o valor de 0,58 (**Tabela 7**). Ou seja, neste caso, ao valor estar abaixo dos 0,7, isto no índice de correlação, mostra que neste caso estamos perante uma correlação moderada. Ou seja, este valor diz-nos que existe uma correlação, mas que a mesma pode variar. Estando a falar de um valor de 0,58 neste caso, podemos considerar que poderá existir esta tal variação, mas que a mesma não deverá ser muito grande, o que nos ajuda a dizer com alguma certeza a sazonalidade desta família. Neste caso, na família do Mobiliário de Casa de Banho, verificamos que temos um mês de janeiro positivo, mas que o seu melhor período vai ser desde o mês de setembro ao mês de novembro. Por outro lado, vemos que os meses de março, abril e maio é onde se regista uma menor procura por estes produtos.

Família	Correlação de Pearson
Mobiliário de Casa de Banho	0,58

Tabela 7 - Correlação de Pearson da família do Mobiliário de Casa de Banho. Elaboração própria com base em *outputs do Excel*

De seguida, temos os valores da família de Arrumação, onde foram considerados para o estudo diversos móveis como, penteadeira, baú, sapateira, móvel de arrumação, cómoda, cabide, roupeiro e closet (**Figura 6**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Arrumação	105	105	99	94	85	84	88	81	86	85	84	82
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	92	94	97	115	116	117	124	117	129	133	98	82

Figura 6 - Mapa de Sazonalidade (Arrumação). Elaboração própria feita em *Excel*

Neste caso, o valor da correlação de Pearson obtido nesta família corresponde a 0,74 (**Tabela 8**), o que quer dizer que estamos perante uma correlação forte. Isto mostra que, a sazonalidade encontrada no mapa corresponde ao que foi obtido quer por dados internos quer externos, dando uma certeza de como a procura por este tipo de produtos acontece ao longo do ano. Neste caso verificamos que, existe uma grande procura que começa a meio de agosto e vai até novembro, inclusive. Por outro lado, de março a junho a procura é fraca.

Família	Correlação de Pearson
Arrumação	0,74

Tabela 8 - Correlação de Pearson da família de Arrumação. Elaboração própria com base em *outputs do Excel*

No seguimento obtivemos os valores para a família da Consola/Mesa de Apoio, que foram considerados tal como o nome diz, consolas e mesas de apoio (**Figura 7**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Consola/Mesa Apoio	102	100	95	98	91	85	82	83	87	77	74	82
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	105	119	116	105	98	104	104	108	124	142	121	98

Figura 7 - Mapa de Sazonalidade (Consola/Mesa de Apoio). Elaboração própria feita em *Excel*

Neste caso verificamos que, no estudo desta família, o valor da correlação de Pearson foi de 0,07 (**Tabela 9**). Isto diz-nos que estamos perante uma correlação fraca, e estado perto de um valor próximo de 0, podemos dizer que a correlação entre os dados internos e externos que temos para o estudo desta família é praticamente inexistente. Por isso, verificamos que mapa de sazonalidade descoberto para esta família pode não corresponder ao que realmente acontece no mercado, ou seja, os períodos identificados podem não corresponder aos períodos de maior procura destes produtos.

Família	Correlação de Pearson
Consola/Mesa de Apoio	0,07

Tabela 9 - Correlação de Pearson da família de Consola/Mesa de Apoio. Elaboração própria com base em *outputs* do *Excel*

A próxima família a que analisou os valores obtidos foi a família da Decoração, em que para o estudo foram considerados muitos produtos, sendo esta a maior família em estudo. Nela estão contidas as velas, o castiçal, as flores artificiais, o biombo, vasos de flores, estatuetas, o espelho, objetos de decoração de parede, papel de parede, molduras, relógio de parede e os quadros (**Figura 9**). Nesta família, no entanto, verificamos que o espelho tem mais de 50% do total do peso da família, quer nos dados internos quer nos dados externos, levando a que neste caso específico tenha sido feito também um estudo apenas para esse produto (**Figura 8**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Decoração	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	99	102	104	103	98	100	94	95	96	96	89	84
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	91	101	85	94	94	97	97	103	127	143	114	89

Figura 9 - Mapa de Sazonalidade (Decoração). Elaboração própria feita em *Excel*

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Decoração (Espelho)	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	108	106	106	105	96	96	92	90	91	93	87	85
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	95	93	88	106	101	99	98	100	124	144	107	87

Figura 8 - Mapa de Sazonalidade (Espelho). Elaboração própria feita em *Excel*

Nesta família de produtos, verificamos que o valor da correlação entre os dados é de 0,37 (**Tabela 10**), o que, de acordo com o índice de correlação, representa uma correlação fraca, não existindo relação entre os dados, pelo que não é possível validar com confiança o mapa de sazonalidade desta categoria. No entanto, quando analisamos especificamente os dados relativos aos espelhos, a correlação de Pearson é de 0,7 (**Tabela 10**), indicando uma correlação moderada, mas sendo praticamente uma correlação forte. Com base nestes resultados, podemos afirmar com alguma certeza, embora podendo existir algumas variações, que os meses de janeiro, fevereiro, novembro e a primeira quinzena de dezembro correspondem ao melhor período para este tipo de produto. Em contrapartida, abril, maio e junho apresentam-se como os meses de menor procura, sendo junho o pior mês.

Família	Correlação de Pearson
Decoração	0,37
Espelho	0,70

Tabela 10 - Correlação de Pearson da família de Decoração e do produto Espelho. Elaboração própria com base em *outputs* do Excel

No estudo da família de decoração de mesa, foram considerados vários produtos como bandeja, talher, pratos, tigela, chávena, travessa, copo, jarro e caneca (**Figura 10**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Decoração Mesa	95	94	102	100	91	89	83	77	86	84	78	83
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	97	92	80	93	92	95	95	107	132	170	163	127

Figura 10 - Mapa de Sazonalidade (Decoração de mesa). Elaboração própria feita em Excel

Os valores da correlação de Pearson que esta família de produtos teve foi de 0,74 (**Tabela 11**), ou seja, estamos a falar de uma correlação forte, tendo em consideração o índice de correlação, entre os dados internos e externos. Com isso, verificamos que neste tipo de produtos, o seu melhor período de procura vai ser no final do ano, com o final do mês de outubro e com os meses de novembro e dezembro. Por outro lado, vemos que sobretudo os meses de abril, maio e junho é o pior período para esta família de produtos.

Família	Correlação de Pearson
Decoração de Mesa	0,74

Tabela 11 - Correlação de Pearson da família de Decoração de Mesa. Elaboração própria com base em *outputs* do Excel

Na seguinte família de produtos, Decoração Têxtil, a mesma apresenta apenas um produto pois, foi apenas o único em que foi possível retirar valores a partir dos dados internos e dados externos, sendo esse produto as almofadas de decoração (**Figura 11**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Decoração Têxtil (Almofada)	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	87	94	96	94	86	95	100	103	105	98	97	98
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	122	132	133	120	102	91	90	87	98	106	88	76

Figura 11 - Mapa de Sazonalidade (Decoração Têxtil). Elaboração própria feita em Excel

O valor da correlação de Pearson obtido foi de 0,44 (**Tabela 12**), indicando uma correlação moderada. Isso significa que o mapa de sazonalidade criado pode não refletir totalmente a realidade, existindo algumas variações, sobretudo por estar próximo de uma correlação fraca. Ainda assim, é possível identificar tendências na procura por este produto: os meses de julho e agosto destacam-se como período de maior procura, seguidos por abril e início de maio. Já o período de dezembro a março apresenta uma procura mais baixa.

Família	Correlação de Pearson
Decoração Têxtil	0,44

Tabela 12 - Correlação de Pearson da família de Decoração Têxtil. Elaboração própria com base em *outputs* do Excel

A seguinte família a ser analisada é a família da Iluminação, onde está o abajur, o candeeiro de teto e o candeeiro (**Figura 12**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Iluminação	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	108	115	106	104	96	89	89	84	102	83	79	82
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	89	86	92	100	105	102	108	108	122	143	111	87

Figura 12 - Mapa de Sazonalidade (Iluminação). Elaboração própria feita em Excel

O valor da correlação de Pearson obtido nesta família foi de 0,56 (**Tabela 13**), indicando uma correlação moderada, o que mostra que os valores apresentados podem ter alguma variação. Na família de produtos de Iluminação, o melhor período é de outubro ao início de dezembro, e também o mês de janeiro. Por outro lado, o pior período vai desde o final de março ao início de agosto, com exceção para a primeira quinzena de maio.

Família	Correlação de Pearson
Iluminação	0,56

Tabela 13 - Correlação de Pearson da família de Iluminação. Elaboração própria com base em *outputs* do Excel

De seguida, analisamos os valores obtidos na família das Janelas, onde são considerados os cortinados e os estores (**Figura 13**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Janelas	106	117	115	121	99	97	96	93	90	90	88	87
	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro						
	100	96	97	110	103	99	99	98	112	112	95	89

Figura 13 - Mapa de Sazonalidade (Janelas). Elaboração própria feita em *Excel*

Nesta família, o valor de correlação de Pearson a que se chegou foi de 0,73 (**Tabela 14**), correspondendo a uma correlação forte. Ou seja, conseguimos verificar que, para estes produtos o seu melhor período de procura acontece nos meses de janeiro, fevereiro, novembro e depois o final e agosto e início de setembro. Enquanto a procura vai ser mais baixa de abril a junho.

Família	Correlação de Pearson
Janelas	0,73

Tabela 14 - Correlação de Pearson da família das Janelas. Elaboração própria com base em *outputs* do *Excel*

Na seguinte família, foi analisada a família do Jardim, que são considerados vários produtos como a cama de rede, a espreguiçadeira, o toldo e o mobiliário de jardim (**Figura 14**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Jardim	41	57	67	78	78	106	138	199	162	160	165	158
	Julho	Agosto	Setembro	Outubro	Novembro	Dezembro						
	152	149	149	127	79	65	58	54	50	42	74	29

Figura 14 - Mapa de Sazonalidade (Jardim). Elaboração própria feita em *Excel*

No estudo desta família, verificamos que o valor da correlação de Pearson que foi obtido foi de 0,86 (**Tabela 15**), ou seja, existe uma correlação forte entre os dados. Com isso podemos identificar que, para esta família existe um padrão de sazonalidade bem identificado, em que procura começa no final de março e vai até ao final de agosto, atingido o seu pico no final do mês de abril. No restante período verificamos que a procura é baixa por este tipo de produtos, existindo um pequeno *outlier* no início do mês de dezembro.

Família	Correlação de Pearson
Jardim	0,86

Tabela 15 - Correlação de Pearson da família do Jardim. Elaboração própria com base em *outputs* do *Excel*

A família que se destaca a seguir para o estudo dos seus valores é a família da *Literie*, onde nesta está contida produtos como edredons, almofadas de dormir, colchões e estrados (Figura 15).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Literie	105	104	104	91	79	78	86	83	84	80	79	80
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	97	97	104	118	108	107	111	121	137	144	106	84

Figura 15 - Mapa de Sazonalidade (*Literie*). Elaboração própria feita em *Excel*

A correlação de Pearson obtida nesta família foi de 0,68 (Tabela 16), sendo considerada moderada. Embora possam existir algumas variações, por estar próxima de uma correlação forte (0,7), esta variação tende a ser reduzida. Assim, o melhor período para esta família de produtos vai do início de agosto até ao início de dezembro, existindo também um desempenho razoável nas três primeiras quinzenas do ano. Já entre o início de março e o fim de junho registam-se os piores resultados.

Família	Correlação de Pearson
<i>Literie</i>	0,68

Tabela 16 - Correlação de Pearson da família da *Literie*. Elaboração própria com base em *outputs* do *Excel*

A próxima família de produtos que foi analisada foi a família Mesa/Cadeira, que tal como o nome diz, tem como produtos em análise as mesas e cadeiras (Figura 16).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Mesa/Cadeira	115	109	105	96	96	87	86	88	90	90	88	89
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	94	97	92	113	117	106	99	100	116	137	101	85

Figura 16 - Mapa de Sazonalidade (Mesa/Cadeira). Elaboração própria feita em *Excel*

Os valores da correlação de Pearson desta família é de 0,09 (Tabela 17), indicando uma correlação fraca, sendo praticamente nula. Isto diz-nos que os valores a que chegamos ao nosso gráfico podem não refletir a realidade, faltando validação na comparação entre os dados internos e externos.

Família	Correlação de Pearson
Mesa/Cadeira	0,09

Tabela 17 - Correlação de Pearson da família das Mesas e Cadeiras. Elaboração própria com base em *outputs* do *Excel*

De seguida foi analisada a família do Mobiliário de Cozinha, que apenas contém um único objeto para o seu estudo que é os armários de cozinha (**Figura 17**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Mob. Cozinha	101	92	104	126	90	97	85	75	73	73	71	92
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	80	93	100	149	115	131	122	121	119	128	96	68

Figura 17 - Mapa de Sazonalidade (Mobiliário de Cozinha). Elaboração própria feita em *Excel*

Na análise desta família, verificamos que o valor de correlação de Pearson que obtemos é de 0,03 (**Tabela 18**), o que nos diz que estamos com uma correlação nula entre os dados. Devido a isso, os valores a que chegamos no mapa de sazonalidade não conseguem ser validados, ou seja, não é possível verificar a sazonalidade desta família de produtos, ou neste caso, dos armários de cozinha.

Família	Correlação de Pearson
Mobiliário de Cozinha	0,03

Tabela 18 - Correlação de Pearson da família do Mobiliário de Cozinha. Elaboração própria com base em *outputs do Excel*

Na seguinte família de produtos é analisada a família do Mobiliário de Escritório, onde na mesma se encontram as cadeiras de escritório e as secretárias, para se fazer o estudo da mesma (**Figura 18**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Mob. Escritório	107	94	88	88	82	74	82	72	79	75	70	74
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	90	86	94	123	156	144	131	125	128	143	109	82

Figura 18 - Mapa de Sazonalidade (Mobiliário de Escritório). Elaboração própria feita em *Excel*

A correlação de Pearson obtida para esta família foi de 0,79 (**Tabela 19**), indicando uma correlação forte, validando o mapa de sazonalidade. A procura por estes produtos concentra-se sobretudo, entre o final de agosto e o início de dezembro, com um pico em setembro. Já entre março e junho, a procura é mais baixa.

Família	Correlação de Pearson
Mobiliário de Escritório	0,79

Tabela 19 - Correlação de Pearson da família do Mobiliário de Escritório. Elaboração própria com base em *outputs do Excel*

Na família de produtos seguintes, é analisada a família do Mobiliário Principal, família essa que tem em análise produtos como o louceiro, a vitrine, o aparador e a estante (**Figura 19**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Mob. Principal	117	119	108	102	92	88	86	84	87	84	85	86
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	96	91	95	107	107	106	108	109	121	133	96	83

Figura 19 - Mapa de Sazonalidade (Mobiliário Principal). Elaboração própria feita em Excel

Na análise desta família, a correlação de Pearson foi de 0,59 (**Tabela 20**), indicando uma correlação moderada. O mapa de sazonalidade criado é razoável, embora sujeito a algumas variações. A procura concentra-se entre o final de agosto e o final de novembro, com um pico no final de novembro, e também nos meses de janeiro e fevereiro. Já entre março e junho, além da última quinzena de dezembro, registam-se os piores valores.

Família	Correlação de Pearson
Mobiliário Principal	0,59

Tabela 20 - Correlação de Pearson da família do Mobiliário Principal. Elaboração própria com base em *outputs* do Excel

A seguinte família de produtos a ser analisada é a família do Quarto, que contém produtos como mesa de cabeceira, cabeceira e cama (**Figura 20**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Quarto	100	103	100	99	93	90	90	88	93	90	86	88
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	99	100	103	116	114	109	110	107	118	128	92	77

Figura 20 - Mapa de Sazonalidade (Quarto). Elaboração própria feita em Excel

Nesta família, a correlação de Pearson foi de 0,63 (**Tabela 21**), indicando uma correlação moderada, mas próxima de uma correlação forte, sugerindo pouca variação dos valores. A procura por produtos desta família é maior entre o final de agosto e o final de novembro, com picos no final de agosto, início de setembro e novembro. Já entre março e junho, e em dezembro, registam-se os valores mais baixos de procura.

Família	Correlação de Pearson
Quarto	0,63

Tabela 21 - Correlação de Pearson da família do Quarto. Elaboração própria com base em *outputs* do Excel

A próxima família a ser observada é a família da Roupa de Cama, família essa que tem para o estudo produtos como o lençol, a fronha, a capa de edredom e a colcha (**Figura 21**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Roupa Cama	115	107	98	84	78	77	81	75	81	80	80	86
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	96	96	108	119	117	108	105	116	132	144	119	96

Figura 21 - Mapa de Sazonalidade (Roupa de Cama). Elaboração própria feita em *Excel*

No estudo da família da Roupa de Cama, verificou-se que a correlação de Pearson da mesma é de 0,76 (**Tabela 22**), o que nos diz que estamos perante uma correlação forte. Isso permite-nos identificar corretamente o período sazonal para esta família de produtos. Com isso vemos que, o melhor período regista-se entre agosto e o início de dezembro, em que o pico se encontra no mês de novembro, destacando também os bons valores registados no mês de janeiro. Por outro lado, do fim de fevereiro ao fim de junho os valores encontrados são baixos.

Família	Correlação de Pearson
Roupa de Cama	0,76

Tabela 22 - Correlação de Pearson da família da Roupa de Cama. Elaboração própria com base em *outputs* do *Excel*

Na família seguinte, que é a família da Roupa de Cozinha, a mesma teve apenas um produto para análise que é o Avental (**Figura 22**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
Roupa Cozinha (Avental)	99	119	99	107	104	104	91	103	101	112	91	92
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	98	102	85	81	94	113	89	79	102	130	123	78

Figura 22 - Mapa de Sazonalidade (Roupa de Cozinha). Elaboração própria feita em *Excel*

Neste caso, verificamos que o valor da correlação de Pearson que foi obtido foi de -0,20 (**Tabela 23**). Ou seja, é uma correlação nula e inversa, ou seja, quando os dados internos subirem, os dados externos começam a fazer o contrário, descem. Ou seja, nesta família não é possível determinar o seu mapa de sazonalidade.

Família	Correlação de Pearson
Roupa de Cozinha	-0,20

Tabela 23 - Correlação de Pearson da família da Roupa de Cozinha. Elaboração própria com base em *outputs* do *Excel*

No seguimento, foi analisada a família dos Tapetes, em que o objeto em estudo foram os próprios tapetes (**Figura 23**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Tapetes	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	126	123	111	107	100	98	90	82	88	88	82	84
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	85	84	92	96	98	90	98	103	121	139	116	94

Figura 23 - Mapa de Sazonalidade (Tapetes). Elaboração própria feita em Excel

Neste caso, verificamos que no estudo desta família, o valor da correlação de Pearson da mesma é de 0,71 (**Tabela 24**), correspondendo a uma correlação forte entre os dados internos e externos. Com isso podemos constatar que, existem dois bons períodos para esta família, que é o mês de janeiro e de fevereiro e depois temos o mês de novembro e início de dezembro. Por outro lado, o pior período entre abril e o início de agosto.

Família	Correlação de Pearson
Tapetes	0,71

Tabela 24 - Correlação de Pearson da família dos Tapetes. Elaboração própria com base em outputs do Excel

A seguinte família a ser analisada foi a família do Têxtil de Banho, que contém as toalhas de banho, os roupões e as toalhas de praia para o seu estudo (**Figura 24**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Têxtil Banho	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	109	101	93	73	71	65	74	78	84	85	91	112
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	126	129	125	110	88	77	84	89	115	153	147	119

Figura 24 - Mapa de Sazonalidade (Têxtil de Banho). Elaboração própria feita em Excel

Nesta família como se verifica, temos produtos que apresentam uma sazonalidade diferente, o que faz com que a análise dos mesmos acabe por ser feita também individualmente, em que temos a análise da sazonalidade das toalhas de praia (**Figura 25**) e

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Têxtil Banho (Toalha Praia)	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	7	11	22	12	34	46	92	140	146	156	186	273
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	325	297	285	187	77	28	28	7	7	11	17	6

Figura 26 - Mapa de Sazonalidade (Toalha de Praia). Elaboração própria feita em Excel

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Têxtil Banho (Toalha Banho/Roupão)	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	135	122	109	90	81	69	71	63	69	67	66	71
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena	1 Quizena	2 Quizena
	75	86	85	91	91	91	100	111	142	187	178	150

Figura 26 - Mapa de Sazonalidade (Toalha de Banho e Roupão). Elaboração própria feita em Excel

de banho e roupões (**Figura 26**).

Ao analisar toda a família em conjunto, a correlação de Pearson é de 0,48 (**Tabela 25**), indicando uma correlação moderada, com alguma variação no mapa identificado. Quando feita uma análise separadamente, a correlação para as toalhas de praia é de 0,98 (**Tabela 25**) e para as toalhas de banho e roupões é de 0,72 (**Tabela 25**), tendo ambas uma correlação forte. A procura por toalhas de praia é maior entre o final de abril e o fim de agosto, enquanto do final de setembro até março a procura fica baixa. Já na procura por toalhas de banho e roupões destaca-se o período entre o fim de outubro e o início de fevereiro, sendo o período com procura mais baixa vai de março a julho.

Família	Correlação de Pearson
Têxtil Banho	0,48
Toalha de Praia	0,98
Toalha de Banho e Roupão	0,72

Tabela 25 - Correlação de Pearson da família de Têxtil de Banho. Elaboração própria com base em *outputs* do Excel

Por fim, a análise da última família, a família do Têxtil de Mesa, que para o estudo contém os produtos de toalhas de mesa e guardanapo (**Figura 27**).

Mês	Janeiro		Fevereiro		Março		Abril		Maio		Junho	
Têxtil Mesa	103	90	88	74	90	70	75	76	87	83	86	104
	Julho		Agosto		Setembro		Outubro		Novembro		Dezembro	
	110	115	106	99	86	73	86	98	137	174	171	124

Figura 27 - Mapa de Sazonalidade (Têxtil de Mesa). Elaboração própria feita em Excel

Na análise desta família, o valor da correlação de Pearson que se obteve foi de 0,31 (**Tabela 26**). Este valor diz-nos que que estamos perante uma correlação fraca, ou seja, que não existe uma grande correlação entre os dados internos e os dados externos, o que nos diz que o mapa de sazonalidade desta família pode não corresponder totalmente ao que realmente acontece na procura por este tipo de produtos.

Família	Correlação de Pearson
Têxtil de Mesa	0,31

Tabela 26 - Correlação de Pearson da família de Têxtil de Mesa. Elaboração própria com base em *outputs* do Excel

4.4. Discussão

A criação deste mapa de sazonalidade serviu para desde logo, para ajudar a responder à questão de investigação do trabalho que é “Como é que a análise de dados internos e externos contribui para a compreensão do comportamento de compra e identificação de tendências sazonais de consumo de produtos para casa (mobiliário e têxtil-lar) no mercado de *e-commerce*?”. Ou seja, com o mapa de sazonalidade, para grande parte da categoria de produtos de casa, vai ser possível identificar as tendências de procura e consumo de determinado produto e com isso, conseguimos ter uma melhor perceção do comportamento de compra dos consumidores para esta categoria de produtos, verificando que na maioria dos casos existe uma sazonalidade que, caso consiga ser aproveitada pode ser benéfica para uma organização, neste caso a La Redoute Portugal, comercializar os seus produtos.

A análise da correlação de Pearson na construção do mapa de sazonalidade revelou um valor geral de 0,67 (**Tabela 28**), indicando uma correlação moderada entre todos os dados externos (*Google Trends*) e todos os dados internos (*PDP Views*). Embora este valor sugira uma associação significativa, também evidencia que pode haver alguma variação nos padrões identificados. O facto de a correlação estar próxima de 0,7 sugere que, no geral, a variação dos valores encontrados no mapa será reduzida, garantindo um nível de confiança razoável nos padrões sazonais identificados.

No entanto, verificou-se que algumas famílias de produtos, nomeadamente têxtil de mesa, roupa de cozinha, mobiliário de cozinha, mesa/cadeira, decoração e consola/mesa de apoio, apresentaram valores de correlação abaixo de 0,4 (**Tabela 27**).

Estes valores indicam uma correlação fraca, o que dificulta a validação da sazonalidade para estas categorias. Por este motivo, apesar de estas famílias terem sido consideradas na construção do mapa de sazonalidade, não serão incluídas na análise final, uma vez que a sua baixa correlação compromete a fiabilidade dos padrões descobertos. Esta decisão reforça a importância de trabalhar com dados validados, garantindo que as conclusões retiradas sejam robustas e aplicáveis.

Família	Correlação de Pearson	Escala do Coeficiente de Pearson
Têxtil de Mesa	0,310	Correlação Fraca
Têxtil Banho	0,480	Correlação Moderada
Toalha de Praia	0,980	Correlação Forte
Toalha de Banho e Roupão	0,720	Correlação Forte
Tapetes	0,710	Correlação Forte
Roupa de Cozinha	-0,200	Correlação Fraca
Roupa de Cama	0,760	Correlação Forte
Quarto	0,630	Correlação Moderada
Mobiliário Principal	0,590	Correlação Moderada
Mobiliário de Escritório	0,790	Correlação Forte
Mobiliário de Cozinha	0,030	Correlação Fraca
Mesa/Cadeira	0,090	Correlação Fraca
Literie	0,680	Correlação Moderada
Jardim	0,860	Correlação Forte
Janelas	0,730	Correlação Forte
Iluminação	0,560	Correlação Moderada
Decoração Têxtil	0,440	Correlação Moderada
Decoração de Mesa	0,740	Correlação Forte
Decoração	0,370	Correlação Fraca
Espelho	0,700	Correlação Moderada
Consola/Mesa de Apoio	0,070	Correlação Fraca
Arrumação	0,740	Correlação Forte
Mobiliário de Casa de Banho	0,580	Correlação Moderada
Sofás	0,800	Correlação Forte

Tabela 27 - Escala do Coeficiente de Pearson das famílias de produtos para casa. Elaboração própria com base em *outputs* do Excel

Família	Correlação de Pearson
Todas as famílias de produtos	0,67

Tabela 28 - Correlação de Pearson de todas as famílias de produtos. Elaboração própria com base em *outputs* do Excel

Os restantes resultados obtidos através do estudo confirmam, em grande parte, o conhecimento já existente, tanto por parte da La Redoute Portugal como do senso comum. Afinal, todos somos consumidores e certos padrões de compra mantêm-se constantes, independentemente do tipo de produto adquirido.

Desde logo, verifica-se que os períodos de maior procura, e consequente concretização de compras, coincidem frequentemente com campanhas promocionais. Observa-se que novembro é um dos meses mais rentáveis, impulsionado pelas promoções da *Black Friday* e pelo facto de coincidir com o pagamento do subsídio de Natal, o que aumenta o poder de compra dos consumidores. Este padrão repete-se nos períodos de saldos, tanto de inverno como de verão, sendo que a procura varia consoante a estação: nos saldos de verão, os produtos relacionados com essa época registam maior procura, e o mesmo acontece nos saldos de inverno.

Duas categorias de produtos distinguem-se das restantes, apresentando padrões sazonais específicos: os artigos de verão e de exterior, como toalhas de praia e mobiliário de jardim. Estes produtos registam o seu pico de procura entre abril e junho, período que, para a maioria dos outros produtos, corresponde a uma fase de menor procura. Além disso, foi possível identificar um aumento na procura de determinados produtos em momentos específicos do ano. Por exemplo, em setembro, verifica-se um pico na procura de mobiliário de escritório, roupa de cama e mobiliário para quarto, possivelmente associado ao início do ano letivo escolar. Da mesma forma, os artigos de decoração de mesa registam maior procura em períodos festivos, como a Páscoa e o Natal.

Assim, o mapa de sazonalidade não só valida padrões previamente identificados, como também permite uma definição mais precisa dos melhores e piores períodos de venda, bem como da duração de cada um. Com esta análise detalhada, os gestores podem estruturar melhor as suas estratégias e planear quais os produtos que devem ter maior ou menor relevância em determinados períodos. No caso da La Redoute Portugal, este mapa servirá como suporte à definição do planeamento comercial, ajudando a otimizar os recursos da empresa e a garantir que os produtos mais procurados estão disponíveis no momento certo.

Contudo, a construção deste estudo enfrentou algumas limitações, sobretudo relacionadas com a recolha de dados. Existem poucos dados externos disponíveis para esta categoria de produtos, o que condiciona a realização de uma análise mais abrangente. Atualmente, a recolha de dados externos baseia-se exclusivamente no *Google Trends*, ferramenta que apresenta diversas restrições.

Entre estas limitações, destaca-se a dificuldade em obter resultados para determinadas palavras-chave, que podem não ser suficientemente relevantes para a escala do *Google Trends*, ou a ambiguidade de termos, como é o caso da palavra "banco", que pode referir-se tanto a uma instituição financeira como a um móvel. Como a ferramenta não permite segmentar este tipo de pesquisa, os dados recolhidos podem não ser totalmente fiáveis. Outra limitação prende-se com a definição das ponderações atribuídas a cada categoria de dados. No presente estudo, foi estipulado que os dados do *Google Trends* teriam um peso de 65%, as visualizações no site 25% e os lucros obtidos pela La Redoute Portugal 15%. No entanto, esta distribuição foi definida internamente, sem uma referência concreta que valide a melhor forma de atribuir estas ponderações.

Para investigações futuras, seria relevante incluir outras fontes de dados externos, como por exemplo, informações provenientes das redes sociais, que podem ajudar a identificar tendências virais ou dados macroeconómicos, que influenciam a sazonalidade do consumo. Além disso, pode existir também a recolha de dados da concorrência através de um processo de *benchmarking*, capaz de fornecer *insights* adicionais ao estudo. Outra possível abordagem seria a aplicação de modelos preditivos avançados para melhorar a precisão na previsão dos ciclos de consumo, assim como a adoção de novos métodos de normalização de dados, tornando a análise ainda mais robusta e fiável.

5. Conclusão

Com base no estágio curricular realizado na La Redoute Portugal e na elaboração deste relatório, posso afirmar que ambos desempenharam um papel fundamental no meu percurso académico, bem como no enriquecimento do conhecimento adquirido para o meu desenvolvimento profissional. Este estágio proporcionou-me uma visão abrangente sobre a forma como uma grande empresa como a La Redoute Portugal trabalha os seus dados e como estes se tornam uma ferramenta essencial no suporte à estratégia organizacional.

O estudo desenvolvido centrou-se na forma como os dados, tanto internos como externos, podem fornecer conhecimento útil para as empresas, permitindo identificar padrões sazonais de consumo em produtos para casa no mercado de *e-commerce*. Através da correlação de Pearson entre os dados externos e internos, foi possível validar se o mapa de sazonalidade criado, com base no processo de KDD, continha informação relevante e aplicável à realidade da La Redoute Portugal.

Os resultados obtidos demonstram que a sazonalidade varia consoante a categoria de produto, tornando necessária uma abordagem comercial mais complexa e adaptada a cada caso. No entanto, é importante destacar que fatores como campanhas promocionais ou mudanças económicas podem influenciar os padrões identificados, levantando questões sobre a estabilidade das tendências observadas. Assim, futuros estudos poderão explorar modelos preditivos mais avançados para melhorar a precisão da análise. Ainda assim, este estudo reforça a importância e o potencial da integração de diferentes fontes de dados na compreensão da sazonalidade dos produtos, neste caso, no setor de artigos para casa nas lojas *online*.

Este relatório, tanto na sua componente teórica como na proposta apresentada, permitiu-me aprofundar conhecimentos sobre *data analytics* e a sua relevância no contexto empresarial, sobretudo em organizações cuja estratégia se baseia fortemente na recolha e análise de dados. Do ponto de vista teórico, evidenciou-se a importância da recolha de dados para o estudo do comportamento dos consumidores, nomeadamente na identificação de possíveis padrões futuros. Já a proposta desenvolvida teve como base não só a revisão da literatura, mas também a experiência adquirida ao longo do estágio, permitindo um aprofundamento do conhecimento que ia sendo obtido.

A proposta foi concebida para apoiar a La Redoute Portugal na criação do seu plano comercial, proporcionando um melhor entendimento do mercado de produtos para casa. No entanto, esta abordagem pode ser adaptada a outras empresas ou mercados, desde que a base metodológica seja mantida. Durante a sua construção, surgiram algumas limitações, mas, apesar disso, a proposta oferece *insights* relevantes e viáveis para futuras implementações.

Referências Bibliográficas

- Ackoff, R. L. (1989). From data to wisdom. *Journal of Applied Systems Analysis*, 16, 3-9.
- Adrian, C., Abdullah, R., Atan, R., & Jusoh, Y. Y. (2018). Conceptual model development of big data analytics implementation assessment effect on decision-making. *International Journal of Interactive Multimedia and Artificial Intelligence*, 5, 101-106. <http://doi.org/10.9781/ijimai.2018.03.001>
- Aggarwal, C. C. (2015). *Data Mining: The Textbook*. Springer.
- Ajzen, I., & Fishbein, M. (1980). *Understanding Attitudes and Predicting Social Behavior*. Prentice-Hall.
- Anderson, W. T., & Golden, L. L. (1984). Lifestyle and psychographics: a critical review and recommendation. *Advances in consumer research*, 11, 405-411.
- Appleyard, M. M., Enders, A. H., & Velazquez, H. (2020). Regaining R&D leadership: the role of design thinking and creative forbearance. *California Management Review*, 62(2), 12-29. <https://doi.org/10.1177/0008125619897395>
- Aris, N. B., Latif, R. A., Zainal, N. S., & Razman, K. K. (2021). Factors affecting young shoppers' online shopping preference in Kelantan, Malaysia. *International Journal of Academic Research in Business and Social Sciences*, 11(14), 417-430. <http://dx.doi.org/10.6007/IJARBSS/v11-i14/9618>
- Babbie, E. (2013). *The Practice of Social Research (13th. Edition)*. Cengage Learning.
- Beiragh, R. G., Alizadeh, R., Kaleibari, S. S., Cavallaro, F., Zolfani, S. H., Bausys, R., & Mardani, A. (2020). An integrated multi-criteria decision making model for sustainability performance assessment for insurance companies. *Sustainability*, 12(3), 789. <https://doi.org/10.3390/su12030789>
- Bertsimas, D., & Kallus, N. (2019). From predictive to prescriptive analytics. *Management Science*, 66(3), 1025-1044. <https://doi.org/10.1287/mnsc.2018.3253>

- Boone, T. (agosto de 2016). *Fashion Trends 2016: Google Data Shows What Shoppers Want*. Obtido de Think with Google: <https://www.thinkwithgoogle.com/consumer-insights/consumer-trends/fashion-trends-2016-google-data-consumer-insights/>
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time Series Analysis: Forecasting and Control (5th Edition)*. Wiley.
- Brachman, R., & Anand, T. (1996). The process of knowledge discovery in databases. *American Association for Artificial Intelligence*, 37-57.
- Bradlow, E. T., Gangwar, M., Kopalle, P., & Voleti, S. (2017). The role of big data and predictive analytics in retailing. *Journal of Retailing*, 93, 79-95. <https://doi.org/10.1016/j.jretai.2016.12.004>
- Bryman, A. (2016). *Social Research Methods (5th. Edition)*. Oxford University Press.
- Callegari-Jacques, S. M. (2003). *Bioestatística: Princípios e Aplicações*. Artmed.
- Carta, S., Medda, A., Pili, A., Recupero, D. R., & Saia, R. (2019). Forecasting e-commerce products prices by combining an autoregressive integrated moving average (ARIMA) model and *Google Trends* data. *Future Internet*, 11(5), 1-19. <https://doi.org/10.3390/fi11010005>
- Chandra, A. K., & Sinha, D. K. (2013). Factors affecting the online shopping behaviour: a study with reference to bhilai durg. *International Journal of Advanced Research in Management and Social Sciences*, 2(5), 160-177.
- Chanthati, S. R. (2024). An automated process in building organic branding opportunity, budget Intensity, recommendation in seasons with *Google Trends* data . *World Journal of Advanced Engineering Technology and Sciences*, 12(2), 510–523. <https://doi.org/10.30574/wjaets.2024.12.2.0326>
- Chatfield, C. (1995a). *The Analysis of Time Series: An Introduction (5th. Edition)*. Chapman & Hall/CRC.
- Chatfield, C. (1995b). *Problem Solving: A Statistician's Guide (2nd. Edition)*. Chapman and Hall/CRC.

- 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 & Social Change*, *196*, 122824. <https://doi.org/10.1016/j.techfore.2023.122824>
- Cheah, Y. K. (2014). Factors influencing consumer purchase decisions for health-promoting goods and services in malaysia. *The Malaysian Journal of Medical Sciences*, *21*(6), 36-44.
- Chen, J., & Dubinsky, A. J. (2003). A conceptual model of perceived customer value in e-commerce: A preliminary investigation. *Psychology & Marketing*, *20*(4), 377-396. <https://doi.org/10.1002/mar.10076>
- Chen, Z., Ling, K. C., Ying, G. X., & Meng, T. C. (2012). Antecedents of online customer satisfaction in china. *Internacional Business Management*, *6*(2), 168-175. <http://dx.doi.org/10.3923/ibm.2012.168.175>
- Chengalur-Smith, I. N. (1999). The impact of data quality information on decision making: An exploratory analysis. *IEEE Transactions on Knowledge and Data Engineering*, *11*(6), 853 - 864. <https://doi.org/10.1109/69.824597>
- Choi, H., & Varian, H. (2012). Predicting the present with *Google Trends*. *Economic Record*, *88*, 2-9. <https://doi.org/10.1111/j.1475-4932.2012.00809.x>
- Creswell, J. W. (2009). *Research Design: Qualitative, Quantitative, and Mixed Methods Approaches (3rd. Edition)*. Sage Publications.
- Davenport, T. H., & Harris, J. G. (2007). *Competing on analytics: The new science of winning*. Harvard Business Review Press.
- Dholakia, R. R., & Zhao, M. (2010). Effects of online store attributes on customer satisfaction and repurchase intentions. *International Journal of Retail & Distribution Management*, *38*(7), 482-496. <https://doi.org/10.1108/09590551011052098>
- Drucker, P. F. (1973). *Management: Tasks, Responsibilities, Practices*. Harper & Row.
- Engel, J. F., Blackwell, R. D., & Miniard, P. W. (1986). *Consumer Behavior (5th Edition)*. Dryden Press.

- Fayyad, U., Piatetsky-Shapiro, G., & Smyth, P. (1996). From data mining to knowledge discovery in databases, 17(3). *AI Magazine*, 37-54. <https://doi.org/10.1609/aimag.v17i3.1230>
- Festinger, L. (1957). *A theory of cognitive dissonance*. Stanford University Press.
- Field, A. (2018). *Discovering Statistics Using IBM SPSS Statistics (5th. Edition)*. Sage Publications.
- Fishbein, M., & Ajzen, I. (1975). *Belief, Attitude, Intention and Behavior: An Introduction to Theory and Research*. Addison-Wesley.
- Florenthal, B., & Shoham, A. (2010). Four-mode channel interactivity concept and channel preferences. *Journal of Services Marketing*, 24, 29-41. <https://doi.org/10.1108/08876041011017871>
- Fowler, F. J. (2014). *Survey Research Methods (5th. Edition)*. Sage Publications.
- Frawley, W. J., Piatetsky-Shapiro, G., & Matheus, C. J. (1992). Knowledge discovery in databases: An overview. *AI Magazine*, 13(2), 57-70. <https://doi.org/10.1609/aimag.v13i3.1011>
- Freud, S. (1915). Instincts and their vicissitudes. *The Standard Edition of the Complete Psychological Works of Sigmund Freud*, 14, 109-140.
- García, S., Luengo, J., & Herrera, F. (2015). *Data preprocessing in data mining*. Springer.
- Garnier, R., & Belletoile, A. (2019). A multi-series framework for demand forecasts in e-commerce. *arXiv:1905.13614*, 1-7. <https://doi.org/10.48550/arXiv.1905.13614>
- Grashuis, J., Skevas, T., & Segovia, M. S. (2020). Grocery shopping preferences during the covid-19 pandemic. *Sustainability*, 12(13), 5369. <https://doi.org/10.3390/su12135369>
- Grether, D. M., Schwartz, A., & Wilde, L. (1986). The irrelevance of information overload: an analysis of search and disclosure. *Southern California Law Rev*, 59, 277-303. <https://doi.org/20.500.13051/316>

- Gupta, S., Modgil, S., & Gunasekaran, A. (2020). Big data in lean six sigma: a review and further research directions. *International Journal of Production Research*, 58(3), 947-969. <https://doi.org/10.1080/00207543.2019.1598599>
- Han, J., Kamber, M., & Pei, J. (2012). *Data Mining: Concepts and Techniques (3rd. Edition)*. Morgan Kaufmann Publishers.
- Hand, D. J. (1998). Data mining: statistics and more? *The American Statistician*, 52(2), 112-118. <https://doi.org/10.1080/00031305.1998.10480549>
- Hassani, H., & Silva, E. S. (2015). Forecasting with big data: A review. *Annals of Data Science*, 2, 5-19. <https://doi.org/10.1007/s40745-015-0029-9>
- Hazen, B. T., Boone, C. A., Ezell, J. D., & Jones-Farmer, L. A. (2014). Data quality for data science, predictive analytics, and big data in supply chain management: An introduction to the problem and suggestions for research and applications. *International Journal of Production Economics*, 154, 72-80. <https://doi.org/10.1016/j.ijpe.2014.04.018>
- Howard, J. A., & Sheth, J. N. (1969). The theory of buyer behavior. *Journal of the American Statistical Association*, 65(331), 467-487. <http://dx.doi.org/10.2307/2284311>
- Hyndman, R. J., & Athanasopoulos, G. (2021). *Forecasting: Principles and Practice (3th Edition)*. OTexts.
- Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4), 679-688. <https://doi.org/10.1016/j.ijforecast.2006.03.001>
- Imran, M., Asif, M., & Sajjad, W. (2022). Impact of employment status on online shopping preferences: A case study of women in rawalpindi. *Journal of Business Insight and Innovation*, 19-28.
- Janssen, M., Estevez, E., & Janowski, T. (2014). Interoperability in big, open, and linked data--organizational maturity, capabilities, and data portfolios. *Computer*, 47, 44-49. <https://doi.org/10.1109/MC.2014.290>

- Janssen, M., Voort, H. v., & Wahyudi, A. (2017). Factors influencing big data decision-making quality. *Journal of Business Research*, 70, 338-345. <https://doi.org/10.1016/j.jbusres.2016.08.007>
- Jiang, Y., Liu, Y., Shang, J., Yildirim, P., & Zhang, Q. (2018). Optimizing online recurring promotions for dual-channel retailers: Segmented markets with multiple objectives. *European Journal Of Operational Research*, 267(2), 612-627. <https://doi.org/10.1016/j.ejor.2017.11.059>
- Jun, S., Yoo, H. S., & Choi, S. (2018). Ten years of research change using *Google Trends*: From the perspective of big data utilizations and applications. *Technological Forecasting and Social Change*, 130, 69-87. <https://doi.org/10.1016/j.techfore.2017.11.009>
- Kaisler, S., Armour, F., Espinosa, J. A., & Money, W. (2013). Big data: Issues and challenges moving forward. *46th Hawaii International Conference on System Sciences* (pp. 95-103). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/HICSS.2013.645>
- Keller, K. L., & Staelin, R. (1987). Effects of quality and quantity of information on decision effectiveness. *Journal of Consumer Research*, 200-213. <https://doi.org/10.1086/209106>
- Khalil, S., & Belitski, M. (2020). Dynamic capabilities for firm performance under the information technology governance framework. *European Business Review*, 32(2), 129-157. <https://doi.org/10.1108/EBR-05-2018-0102>
- Klatt, S., & Smeeton, N. J. (2020). Immersive screens change attention width but not perception or decision-making performance in natural and basic tasks. *Applied Ergonomics*, 82, 102961. <https://doi.org/10.1016/j.apergo.2019.102961>
- Kotler, P. (1998). *Administração de Marketing: análise, planejamento, implementação (5ª Edição)*. Atlas.
- Kotler, P., Armstrong, G., Saunders, J., & Wong, V. (1999). *Principles of Marketing*. Prentice Hall Inc.

- Keerthika, K., & Saravanan, T. (2020). Enhanced Product Recommendations based on Seasonality and Demography in Ecommerce. *2nd International Conference on Advances in Computing, Communication Control and Networking (ICACCCN)* (pp. 721-723). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICACCCN51052.2020.9362760>
- La Redoute Portugal. (7 de setembro de 2024). *Quem somos*. Obtido de La Redoute Portugal: <https://www.laredoute.pt/services/quemsomos.aspx>
- Larson, J. S., Bradlow, E. T., & Fader, P. S. (2005). An exploratory look at supermarket shopping paths. *International Journal of Research in Marketing*, 22(4), 395-414. <https://doi.org/10.1016/j.ijresmar.2005.09.005>
- Laudon, K. C., & Laudon, J. P. (2020). *Management Information Systems: Managing the Digital Firm (16th Edition)*. Pearson.
- LaValle, S., Lesser, E., Shockley, R., Hopkins, M. S., & Kruschwitz, N. (2011). Big data, analytics and the path from *insights* to value. *MIT Sloan Management Review*, 52, 20–31.
- Liashenko, O., & Yakymchuk, B. (2023). The application of time-series forecasting models in grocery retail industry. *Theoretical and Applied Issues of Economics*, 118-129. <http://dx.doi.org/10.17721/tpe.2023.47.11>
- Lin, R., Xie, Z., Hao, Y., & Wang, J. (2020). Improving high-tech enterprise innovation in big data environment: a combinative view of internal and external governance. *International Journal of Information Management*, 50, 575-585. <https://doi.org/10.1016/j.ijinfomgt.2018.11.009>
- Liu, X., Burns, A. C., & Hou, Y. (2013). Comparing online and in-store shopping behavior towards luxury goods. *International Journal of Retail & Distribution Management*, 41 (11/12), 885-900. <https://doi.org/10.1108/IJRDM-01-2013-0018>
- Lucena, W. G., Medeiros, J. A., Oliveira, A. L., Silva, S. P., & Marcelino, G. F. (2011). Finanças comportamentais: Fatores que influenciam os consumidores na hora da compra. *Revista Estudos do CEPE*, 33, 93-126.

- Maimon, O., & Rokach, L. (2005). *The Data Mining and Knowledge Discovery Handbook*. Springer.
- Malindzakova, M., Malindzak, D., & Kubik, A. (2024). Seasonal data cleaning for sales with chase demand strategy. *Standards*, 4(2), 52-65. <https://doi.org/10.3390/standards4020004>
- Marketeer. (4 de outubro de 2022). *La Redoute revela nova imagem para mostrar como evoluiu na última década*. Obtido de Marketeer: <https://marketeer.sapo.pt/la-redoute-revela-nova-imagem-para-mostrar-como-evoluiu-na-ultima-decada/>
- Maslow, A. H. (1943). A theory of human motivation. *Psychological Review*, 50(4), 370-396. <https://doi.org/10.1037/h0054346>
- Medeiros, J. F., & Cruz, C. M. (2006). Comportamento do consumidor: Fatores que influenciam no processo de decisão de compra dos consumidores. *Teoria e Evidência Econômica*, 44, 167-190.
- Musbah, H., El-Hawary, M., & Aly, H. (2019). Identifying seasonality in time series by applying fast Fourier Transform. *IEEE Electrical Power and Energy Conference (EPEC)* (pp. 1-4). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/EPEC47565.2019.9074776>
- Nalchigar, S., & Weber, I. (2012). A large-scale study of online shopping behavior. *arXiv:1212.5959*, 1-42. <https://doi.org/10.48550/arXiv.1212.5959>
- Neirotti, P., Pesce, D., & Battaglia, B. (2021). Algorithms for operational decision-making: an absorptive capacity perspective on the process of converting data into relevant knowledge. *Technological Forecasting and Social Change*, 173, 121088. <https://doi.org/10.1016/j.techfore.2021.121088>
- Nespolo, D., Dias, D. T., Ganzer, P. P., Nodari, C. H., Figueira, M. V., & Camargo, M. E. (2015). Comportamento do consumidor: fatores que influenciam o consumo virtual nas redes sociais. *Revista Ciências Administrativas*, 21, 288-316. <http://dx.doi.org/10.18226/35353535.v2.2013.62>
- Neuman, W. L. (2014). *Social Research Methods: Qualitative and Quantitative Approaches (7th. Edition)*. Pearson Education.

- Nicosia, F. M. (1966). *Consumer decision processes: Marketing and advertising implications*. Prentice-Hall.
- Norton, M. (1999). Knowledge discovery in databases. *Library Trends*, 48, 9-21.
- Oh, J., Ha, K., & Jo, Y. (2022). A predictive model of seasonal clothing demand with weather factors. *Asia-Pacific Journal of Atmospheric Sciences*, 58, 667–678. <https://doi.org/10.1007/s13143-022-00284-3>
- O'Reilly, C. A. (1982). Variations in decision makers' use of information sources: The impact of quality and accessibility of information. *Academy of Management Journal*, 25(4), 756-771. <https://doi.org/10.5465/256097>
- Parrilla, J. C., Font, A. R., & Nadal, J. R. (2007). Accommodation determinants of seasonal patterns. *Annals of Tourism Research*, 34(2), 422-436. <https://doi.org/10.1016/j.annals.2006.10.002>
- Pavlov, I. P. (1927). *Conditioned Reflexes: An Investigation of the Physiological Activity of the Cerebral Cortex*. Oxford University Press.
- Piatetsky-Shapiro, G. (1991). Knowledge discovery in real databases: A report on the IJCAI-89 work-shop. *AI Magazine*, 11(5), 68-70. <https://doi.org/10.1609/aimag.v11i4.873>
- Piatetsky-Shapiro, G., & Matheus, C. (1994). The interestingness of deviations. *AAAIWS'94: Proceedings of the 3rd International Conference on Knowledge Discovery and Data Mining* (pp. 25-36). AAAI Press.
- Provost, F., & Fawcett, T. (2013). Data Science and Its Relationship to Big Data and Data-Driven Decision Making. *Big Data*, 1, 51-59. <https://doi.org/10.1089/big.2013.1508>
- Rajesh, R. (2018). Evaluating the factors influencing online shopping and its consumer satisfaction in pune area. *International Journal of Social Sciences*, 4, 54-76. <http://dx.doi.org/10.20319/pijss.2018.41.5476>
- Redoute, L. (16 de abril de 2018). *La Redoute: 30 anos em Portugal*. Obtido de La Redoute: <https://www.laredoute.pt/content/la-redoute-30-anos-em-portugal/>
- Redoute, L. (9 de dezembro de 2024). *O Nosso Negócio*. Obtido de R Ways: https://rways.laredoute.com/jcms/jcms/prodtrois_1000132708/pt/o-nosso-negocio

- Redoute, L. (6 de setembro de 2024). *Who are we?* Obtido de La Redoute: <https://www.laredoute.com/whoarewe.aspx>
- Riquelme, I. P., & Rios, R. E. (2010). The moderating effect of gender in the adoption of mobile banking. *International Journal of Bank Marketing*, 28(5), 328-341. <https://doi.org/10.1108/02652321011064872>
- Romero, C., & Ventura, S. (2013). Data mining in education. *WIREs Data Mining Knowl Discov*, 3, 12-27. <https://doi.org/10.1002/widm.1075>
- Roy, P., & Datta, D. (2022). Theory and models of consumer buying behaviour: A descriptive study. *SSRN Electronic Journal*, 11(8), 206-217. <https://dx.doi.org/10.2139/ssrn.4205489>
- Sardana, A., Talwar, P., & Gulati, S. (2018). Seasonal *marketing*: Strategies using the calendar . *International Journal Of Engineering Technologies And Management Research*, 5(2), 126-133. <http://dx.doi.org/10.29121/ijetmr.v5.i2.2018.155>
- Sarkar, R., & Das, S. (2017). Online shopping vs offline shopping : A comparative study. *International Journal of Scientific Research in Science & Technology*, 3, 424-431.
- Schein, E. H. (2010). *Organizational Culture and Leadership (4th ed.)*. Jossey-Bass.
- Schiffman, L. G., & Kanuk, L. L. (1991). *Consumer Behavior (4th Edition)*. Prentice Hall.
- Senge, P. M. (1990). *The Fifth Discipline: The Art & Practice of The Learning Organization*. Doubleday.
- Serra, F. R., Ferreira, M. P., Torres, M. C. & Torres, A. P. (2011). *Gestão Estratégica: Conceitos e Práticas*. LIDEL.
- Shamim, S., Cang, S., & Yu, H. (2019a). Impact of knowledge oriented leadership on knowledge management behaviour through employee work attitudes. *International Journal of Human Resource Management*, 30(16), 2387-2417 <https://doi.org/10.1080/09585192.2017.1323772>.
- Shamim, S., Zeng, J., Shariq, S. M., & Khan, Z. (2019b). Role of big data management in enhancing big data decision-making capability and quality among Chinese firms: a

- dynamic capabilities view. *Information and Management*, 56(6), 103135. <https://doi.org/10.1016/j.im.2018.12.003>
- Shamout, M. (2016). The impact of promotional tools on consumer buying behavior in retail market. *International Journal Of Business And Social Science*, 7, 75-85.
- Sharma, A., Patel, N., & Gupta, R. (2021). Leveraging LSTM and Prophet models for enhanced AI-driven demand prediction in e-commerce. *European Advanced AI Journal*, 10(2), 1-23.
- Shneiderman, B. (1996). The eyes have it: a task by data type taxonomy for information visualizations. *Proceedings 1996 IEEE Symposium on Visual Languages*, 336-343.
- Shugan, S. M., & Radas, S. (2000). Services and Seasonal Demand. Em T. Swartz, & D. Iacobucci, *Handbook of Services Marketing and Management* (pp. 147-170). Sage Publications, Inc.
- Silberschatz, A., & Tuzhilin, A. (1995). On Subjective Measures of Interestingness in Knowledge Discovery. In *Proceedings of KDD-95: First International Conference on Knowledge Discovery and Data Mining* (pp. 275–281). American Association for Artificial Intelligence.
- Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of big data challenges and analytical methods. *Journal of Business Research*, 70, 263-286. <https://doi.org/10.1016/j.jbusres.2016.08.001>
- Shumway, R. H., & Stoffer, D. S. (2011). *Time Series Analysis and Its Applications (3rd Edition)*. Springer
- Stern, H. (1962). The significance of impulse buying today. *Journal of Marketing*, 26(2), 59-62. <https://doi.org/10.1177/002224296202600212>
- Sujata, J., & Menachem, D. (2017). Impact of flash sales on consumers & e-Commerce industry in India. *17th Annual International Conference On Qualitative And Quantitative Economics* , (pp. 1-9).
- Teece, D. J. (2012). Dynamic capabilities: routines versus entrepreneurial action. *Journal of Management Studies*, 49(8), 1395-1401. <https://doi.org/10.1111/j.1467-6486.2012.01080.x>

- Têxtil, P. (23 de março de 2006). *La Redoute: a arte de se adaptar*. Obtido de Portugal Têxtil: <https://portugaltexil.com/la-redoute-a-arte-de-se-adaptar/>
- Thornhill, N. F., & Naim, M. M. (2006). An exploratory study to identify rogue seasonality in a steel company's supply network using spectral principal component analysis. *European Journal of Operational Research*, 172, 146-162. <https://doi.org/10.1016/j.ejor.2004.09.044>
- Tonkin, J. D., Bogan, M. T., Bonada, N., Rios-Touma, B., & Lytle, D. A. (2017). Seasonality and predictability shape temporal species diversity. *Ecology*, 98(5), 1201-1216. <https://doi.org/10.1002/ecy.1761>
- Tseng, H. T., Aghjaali, N., & Hajli, N. (2022). Customer agility and big data analytics in new product context. *Technological Forecasting and Social Change*, 180, 121690. <https://doi.org/10.1016/j.techfore.2022.121690>
- Verma, P., Zhong, S., Liu, X., & Rajan, A. (2023). Seasonality based reranking of e-commerce autocomplete using natural language queries. *arXiv:2308.02055*, 1-6. <https://doi.org/10.48550/arXiv.2308.02055>
- Vishwanath, A., Basheeruddin, M., & Saveetha, D. (2024). Forecasting sales data using time series models and LSTM model. *Second International Conference on Advances in Information Technology (ICAIT)* (pp. 1-6). Institute of Electrical and Electronics Engineers. <https://doi.org/10.1109/ICAIT61638.2024.10690408>
- Visinescu, L. L., Jones, M. C., & Sidorova, A. (2017). Improving decision quality: The role of business intelligence. *Journal of Computer Information Systems*, 57, 58-66. <https://doi.org/10.1080/08874417.2016.1181494>
- Vithayathil, J., Dadgar, M., & Osiri, J. K. (2020). Social media use and consumer shopping preferences. *International Journal of Information Management*, 54, 102117. <https://doi.org/10.1016/j.ijinfomgt.2020.102117>
- Vrontis, D., Chatterjee, S., & Chaudhuri, R. (2021). Does remote work flexibility enhance organization performance? Moderating role of organization policy and top management support. *J. Bus. Res.*, 139, 1501–1512. <https://doi.org/10.1016/j.jbusres.2021.10.069>

- Wedel, M., & Kannan, P. K. (2016). *Marketing analytics for data-rich environments*. *Journal of Marketing*, 80(6), 97–121. <https://doi.org/10.1509/jm.15.0413>
- Witten, I. H., Frank, E., & Hall, M. A. (2011). *Data Mining: Practical Machine Learning Tools and Techniques (3rd. Edition)*. Morgan Kaufmann Publishers.
- Wu, X. (2022). The Use of Big Data in Customer Acquisition and Retention. *Proceedings of the 2022 7th International Conference on Financial Innovation and Economic Development (ICFIED 2022)*. Atlantis Press. <https://doi.org/10.2991/aebmr.k.220307.371>
- Zehir, C., Karaboga, T., & Basar, D. (2020). The transformation of human resource management and its impact on overall business performance: big data analytics and AI technologies in strategic HRM. *Digital Business Strategies in Blockchain Ecosystems*, 265-279. https://doi.org/10.1007/978-3-030-29739-8_12
- Zytek, A., Liu, D., Vaithianathan, R., & Veeramachan, K. (2021). Sibyl: understanding and addressing the usability challenges of machine learning in high-stakes decision making. *IEEE Trans Vis Comput Graph*, 18, 1161-1171. <https://doi.org/10.1109/TVCG.2021.3114864>

Anexos

Anexo A – Mapa de Sazonalidade

Mês	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	Correlação		
Sofás	107	108	106	103	96	91	91	85	89	89	86	80	84	89	87	87	87	87	87	87	87	87	87	87	87	87	87	87	87	87	87	87	0,80	
Mob. Casa Banho	115	107	100	92	85	92	86	82	82	82	85	75	94	110	94	90	90	99	107	118	123	113	135	146	103	83	82	82	82	82	82	82	0,79	
Mob. Escritório	107	94	88	88	82	74	88	86	84	84	84	83	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	0,79	
Mob. Principal	117	119	108	102	92	88	86	86	84	84	87	84	83	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	86	0,79	
Consola/Mesa Apoio	102	100	95	98	91	85	82	83	83	87	77	74	82	105	119	116	105	98	104	104	108	124	142	121	98	101	85	0,07	85	0,07	85	0,07		
Mesa/Cadeira	115	109	105	96	96	87	86	88	88	90	90	88	89	94	91	101	88	94	94	97	97	103	127	145	114	89	0,57	89	0,57	89	0,57			
Decoração	99	102	104	103	98	100	94	95	96	96	96	89	84	91	101	88	88	106	101	99	99	100	103	127	144	114	89	0,57	89	0,57	89	0,57		
Decoração (Espelho)	108	106	105	105	95	95	92	90	91	93	90	87	88	95	93	90	88	106	101	99	99	100	103	124	144	114	89	0,57	89	0,57	89	0,57		
Decoração Mesa	115	107	98	84	78	77	77	81	75	81	80	80	86	96	96	108	119	117	108	105	116	132	144	119	95	0,76	95	0,76	95	0,76	95	0,76		
Roupa Cama	105	104	102	100	91	89	83	83	84	80	79	80	78	97	97	104	118	108	107	111	121	137	144	106	84	0,68	84	0,68	84	0,68	84	0,68		
Litree	95	94	102	100	91	89	83	77	86	84	78	83	83	97	92	104	118	108	107	111	121	137	144	106	84	0,68	84	0,68	84	0,68	84	0,68		
Decoração Mesa	99	116	99	107	104	104	104	101	103	101	112	112	91	92	102	85	81	94	94	113	89	28	102	130	123	79	-0,20	79	-0,20	79	-0,20			
Roupa Cozinha (Avental)	101	92	104	126	90	97	85	85	78	79	79	71	92	80	93	100	148	115	131	122	121	119	128	95	69	0,83	69	0,83	69	0,83	69	0,83		
Mob. Cozinha	87	94	96	94	86	95	100	103	105	98	97	97	98	122	132	133	133	120	102	91	90	87	98	105	88	76	0,44	76	0,44	76	0,44			
Decoração Têxtil (Almofada)	106	117	115	121	99	97	96	93	90	84	85	91	112	126	129	110	110	103	99	99	98	112	112	95	69	0,73	69	0,73	69	0,73	69	0,73		
Janelas	109	101	93	73	71	68	74	78	84	85	91	112	126	129	110	110	103	99	99	98	112	112	95	69	0,73	69	0,73	69	0,73	69	0,73			
Têxtil Banho	106	117	115	121	99	97	96	93	90	84	85	91	112	126	129	110	110	103	99	99	98	112	112	95	69	0,73	69	0,73	69	0,73	69	0,73		
Têxtil Banho (Toalha Banho/Roupaio)	109	101	93	73	71	68	74	78	84	85	91	112	126	129	110	110	103	99	99	98	112	112	95	69	0,73	69	0,73	69	0,73	69	0,73	69	0,73	
Têxtil Banho (Toalha Banho/Roupaio)	135	122	109	90	81	69	71	63	69	67	66	71	71	79	79	86	83	91	91	91	100	111	142	137	178	150	7	6	0,58	7	0,58			
Têxtil Banho (Toalha Banho/Roupaio)	126	123	111	107	100	98	90	82	88	88	82	84	84	85	84	84	84	92	96	98	98	103	121	138	116	94	0,71	94	0,71	94	0,71	94	0,71	
Têxtil Banho (Toalha Banho/Roupaio)	105	105	99	94	85	84	88	81	86	85	84	82	82	92	94	97	115	116	117	124	117	129	137	174	171	124	0,31	124	0,31	124	0,31	124	0,31	
Têxtil Banho (Toalha Banho/Roupaio)	103	90	88	74	90	70	75	76	87	83	86	84	104	110	115	106	99	86	73	86	98	117	129	137	174	171	124	0,31	124	0,31	124	0,31	124	0,31
Têxtil Banho (Toalha Banho/Roupaio)	100	103	100	99	93	90	88	88	88	83	90	86	88	99	100	103	116	114	109	110	107	118	126	92	77	67	0,56	67	0,56	67	0,56	67	0,56	
Têxtil Banho (Toalha Banho/Roupaio)	108	113	106	104	98	89	89	84	84	102	102	83	79	82	82	82	82	92	100	105	102	108	108	122	148	111	67	0,56	67	0,56	67	0,56	67	0,56
Têxtil Banho (Toalha Banho/Roupaio)	41	57	67	78	78	78	106	138	139	162	160	165	158	152	149	149	127	107	79	63	58	54	50	42	74	29	0,56	29	0,56	29	0,56	29	0,56	
Têxtil Banho (Toalha Banho/Roupaio)	101	100	97	93	87	86	89	91	93	91	91	91	98	109	109	108	112	103	99	99	100	116	132	110	84	84	84	84	84	84	84	84	84	

Anexo B – Mapa Sazonalidade (*Google Trends*)

Mes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31	Média																					
Sofas	108	104	95	93	92	92	93	92	89	89	89	88	88	95	100	99	108	108	104	105	110	117	121	105	96	Sofas	108	104	95	93	92	92	93	92	89	89	89	88	95	100	99	108	108	104	105	110	117	121	105	96			
Mob. Casa Banho	117	110	100	103	92	100	79	79	84	84	80	71	79	96	88	93	115	140	124	120	123	124	138	123	103	Mob. Casa Banho	117	110	100	103	92	100	79	79	84	84	80	71	79	96	88	93	115	140	124	120	123	124	138	123	103		
Mob. Escritorio	118	94	85	91	80	76	90	74	84	80	80	71	79	96	88	93	115	140	124	120	123	124	138	123	103	Mob. Escritorio	118	94	85	91	80	76	90	74	84	80	80	71	79	96	88	93	115	140	124	120	123	124	138	123	103		
Mob. Principal	116	124	102	97	93	93	86	91	86	67	83	90	90	90	90	97	106	110	102	102	106	112	121	100	101	Mob. Principal	116	124	102	97	93	93	86	91	86	67	83	90	90	90	97	106	110	102	102	106	112	121	100	101			
Consola/Mesa Apoio	107	96	89	100	94	85	82	81	89	81	79	81	88	88	98	94	98	105	104	104	98	110	124	144	131	Consola/Mesa Apoio	107	96	89	100	94	85	82	81	89	81	79	81	88	88	98	94	98	105	104	104	98	110	124	144	131		
Mesa/Cadeira	96	97	92	93	105	96	91	97	95	97	99	92	95	95	106	101	117	129	100	93	95	99	111	107	103	Mesa/Cadeira	96	97	92	93	105	96	91	97	95	97	99	92	95	106	101	117	129	100	93	95	99	111	107	103			
Decoraçao	95	97	95	96	100	99	97	98	101	99	93	87	89	96	116	97	93	98	99	101	103	105	113	115	106	Decoraçao	95	97	95	96	100	99	97	98	101	99	93	87	89	96	116	97	93	98	99	101	103	105	113	115	106		
Decoraçao (Espelho)	102	103	99	104	102	103	98	97	97	97	93	89	89	96	96	104	104	100	101	102	102	105	111	103	98	Decoraçao (Espelho)	102	103	99	104	102	103	98	97	97	97	93	89	89	96	104	104	100	101	102	102	105	111	103	98			
Roupa Cama	117	97	86	80	79	79	85	82	79	85	86	86	89	98	110	116	121	107	107	104	118	124	127	123	113	Roupa Cama	117	97	86	80	79	79	85	82	79	85	86	86	89	98	110	116	121	107	107	104	118	124	127	123	113		
Literie	101	99	92	91	85	84	87	87	88	88	86	89	92	102	108	110	120	115	107	106	111	117	121	99	95	Literie	101	99	92	91	85	84	87	87	88	88	86	89	92	102	108	110	120	115	107	106	111	117	121	99	95		
Decoraçao Mesa	95	96	97	97	99	97	94	91	94	94	94	91	98	100	101	94	94	96	98	96	96	102	107	116	130	132	Decoraçao Mesa	95	96	97	97	99	97	94	91	94	94	94	91	98	100	101	94	94	96	98	96	96	102	107	116	130	132
Roupa Cozinha (Avental)	108	109	96	104	119	94	94	91	92	100	95	92	98	94	94	94	94	94	94	94	94	94	90	89	79	Roupa Cozinha (Avental)	108	109	96	104	119	94	94	91	92	100	95	92	98	94	94	94	94	94	94	94	94	90	89	79			
Mob. Cozinha	121	111	121	124	101	95	103	98	98	96	88	88	95	94	94	94	94	94	94	94	94	94	90	89	79	Mob. Cozinha	121	111	121	124	101	95	103	98	98	96	88	88	95	94	94	94	94	94	94	94	94	90	89	79			
Decoraçao Textil (Almofada)	91	93	93	95	87	91	95	98	98	96	94	98	102	107	112	114	108	104	102	102	99	106	109	107	98	Decoraçao Textil (Almofada)	91	93	93	95	87	91	95	98	98	96	94	98	102	107	112	114	108	104	102	102	99	106	109	107	98		
Janelas	105	107	100	109	98	99	101	99	99	93	95	94	90	101	101	101	111	106	105	103	103	104	97	94	79	Janelas	105	107	100	109	98	99	101	99	99	93	95	94	90	101	101	101	111	106	105	103	104	97	94	79			
Textil Banho	104	84	77	66	71	61	77	85	88	88	92	102	124	138	138	131	104	86	73	77	87	108	135	156	148	Textil Banho	104	84	77	66	71	61	77	85	88	88	92	102	124	138	138	131	104	86	73	77	87	108	135	156	148		
Textil Banho (Toalha Praia)	0	6	22	0	24	44	88	144	143	166	206	295	341	318	295	182	79	17	11	11	0	0	17	5	Textil Banho (Toalha Praia)	0	6	22	0	24	44	88	144	143	166	206	295	341	318	295	182	79	17	11	11	0	0	17	5				
Textil Banho (Toalha Banho/Roupa)	139	110	95	88	87	67	74	65	69	67	68	67	70	78	76	79	89	93	100	116	143	178	198	193	Textil Banho (Toalha Banho/Roupa)	139	110	95	88	87	67	74	65	69	67	68	67	70	78	76	79	89	93	100	116	143	178	198	193				
Tapetes	109	111	100	103	104	97	92	86	88	89	90	84	89	94	100	96	103	95	104	110	117	119	115	103	Tapetes	109	111	100	103	104	97	92	86	88	89	90	84	89	94	100	96	103	95	104	110	117	119	115	103				
Arrumaçao	111	106	95	94	88	88	90	89	90	93	89	86	95	96	100	112	117	109	108	111	113	111	100	104	Arrumaçao	111	106	95	94	88	88	90	89	90	93	89	86	95	96	100	112	117	109	108	111	113	111	100	104				
Textil Mesa	104	84	77	66	71	61	77	85	88	88	92	102	124	138	138	131	104	86	73	77	87	108	135	156	148	Textil Mesa	104	84	77	66	71	61	77	85	88	88	92	102	124	138	138	131	104	86	73	77	87	108	135	156	148		
Quarto	100	102	93	95	90	93	92	91	93	93	93	90	91	102	108	109	113	114	105	105	110	111	96	95	Quarto	100	102	93	95	90	93	92	91	93	93	93	90	91	102	108	109	113	114	105	105	110	111	96	95				
Iluminaçao	109	113	100	101	94	90	88	89	87	81	83	78	84	89	99	107	110	101	111	112	117	127	124	105	Iluminaçao	109	113	100	101	94	90	88	89	87	81	83	78	84	89	99	107	110	101	111	112	117	127	124	105				
Jardim	51	64	63	73	76	100	125	136	132	142	144	157	165	165	180	159	109	104	96	72	71	61	52	46	49	Jardim	51	64	63	73	76	100	125	136	132	142	144	157	165	165	180	159	109	104	96	72	71	61	52	46	49		
Média	101	96	90	90	89	87	91	93	94	94	97	101	111	114	112	109	104	96	72	72	71	61	52	46	49	Média	101	96	90	90	89	87	91	93	94	94	97	101	111	114	112	109	104	96	72	72	71	61	52	46	49		

Anexo C – Mapa Sazonalidade (*PDP Views*)

Mes	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21	22	23	24	25	26	27	28	29	30	31
Sofás	104	104	111	104	90	79	85	74	86	76	64	65	67	69	77	97	95	113	133	163	167	171	104	98							
Mob. Casa Banho	106	110	107	79	81	87	100	87	90	84	76	81	87	71	77	114	104	131	133	116	145	157	104	98							
Mob. Escritório	89	90	90	79	80	70	73	68	71	66	64	62	79	86	94	131	203	142	136	144	135	81	59								
Mob. Principal	111	108	111	94	84	80	75	80	81	74	85	83	110	99	104	126	105	137	129	116	126	126	85	54							
Mob. Principal (Aparador)	112	106	109	92	83	78	72	80	80	77	91	90	127	110	110	126	94	132	127	110	119	120	85	54							
Consola/Mesa Apoio	89	109	100	81	77	74	72	75	74	64	56	63	139	193	195	135	95	120	115	101	125	112	76	46							
Mesa/Cadeira	162	135	132	104	74	70	70	73	78	75	67	73	87	87	82	107	107	126	114	114	144	147	95	62							
Decoração	105	110	119	110	97	103	93	87	90	87	77	73	77	70	68	92	92	97	94	113	181	174	111	72							
Decoração (Espelho)	117	113	116	100	85	83	83	77	82	84	78	77	80	80	74	108	99	101	103	184	171	109	78								
Roupa Cama	114	118	117	87	74	73	75	64	84	69	66	75	92	93	115	128	117	113	120	141	154	103	70								
Litree	117	119	121	91	74	74	88	79	81	78	61	60	97	78	88	110	99	111	116	135	163	162	105	64							
Decoração/Mesa	102	99	109	104	91	84	87	72	70	67	57	63	77	85	59	76	83	87	86	107	189	265	200	130							
Roupa Cozinha (Amenal)	67	138	113	107	101	135	84	100	136	148	100	98	124	139	76	72	106	85	67	66	92	100	67	37							
Mob. Cozinha	46	61	70	122	116	107	84	39	41	41	50	98	57	76	118	136	171	164	159	191	151	151	87	46							
Decoração (Almofada)	79	91	97	83	73	92	101	107	106	93	92	91	171	204	195	138	95	80	73	70	82	91	57	44							
Janelas	115	136	138	130	93	95	95	86	85	79	79	81	93	89	95	109	104	95	96	100	120	122	90	55							
Textil Banho	118	129	118	83	71	88	76	71	76	71	69	93	105	112	119	119	92	92	96	100	127	179	124	80							
Textil Banho (Toalha Banho/Roupa)	12	19	26	31	45	49	95	126	130	116	159	257	301	289	296	215	72	39	31	18	19	26	15	7							
Tapetes	131	143	129	90	75	71	73	64	69	65	58	72	80	90	97	107	95	98	104	110	141	138	89								
Arrumação	178	161	141	117	93	103	85	68	78	80	67	75	72	70	77	91	87	84	89	93	130	146	107	92							
Textil Mesa	94	102	110	87	87	82	81	77	80	73	63	62	77	78	98	121	127	156	151	143	160	141	83	46							
Quarto	103	99	110	85	109	85	80	64	81	69	59	69	68	75	76	87	81	81	110	128	183	222	160	101							
Iluminação	104	106	111	102	106	91	94	85	91	86	72	70	81	83	94	126	115	127	125	121	130	133	76	51							
Jardim	107	113	118	102	86	88	82	73	147	80	71	80	84	80	89	96	103	107	100	106	134	157	95	69							
Média	27	38	64	68	66	106	148	274	205	188	167	132	107	144	167	136	91	75	49	35	34	34	18	12							
	100	106	107	93	84	85	85	85	92	84	78	84	102	107	109	116	105	110	107	109	133	143	95	61							