

UNIVERSIDADE DE SÃO PAULO
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, CONTABILIDADE E ATUÁRIA
DEPARTAMENTO DE ECONOMIA

NATALIA CRUZ VISCOME

MODELOS DE PREVISÃO DE DEMANDA DE COSMÉTICOS PARA A INDÚSTRIA
VAREJISTA BRASILEIRA

SÃO PAULO
2022

NATALIA CRUZ VISCOME

**Modelos de previsão de demanda de cosméticos para a indústria varejista
brasileira**

Monografia apresentada ao Departamento de Economia da Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo como requisito parcial para obtenção do título de bacharel em Ciências Econômicas.

Orientador: Prof. Dr. Claudio Ribeiro de Lucinda

São Paulo
2022

FICHA CATALOGRÁFICA

Viscome, Natalia Cruz

Modelos de previsão de demanda de cosméticos para a indústria varejista brasileira – São Paulo, 2022.

48 páginas

Área de concentração: Organização Industrial.

Orientador: Prof. Dr. Claudio Ribeiro de Lucinda

Monografia – Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo, Departamento de Economia.

1.Previsão de Vendas; 2. Gestão de Estoques; 3. Planejamento da Produção

AGRADECIMENTOS

Agradeço aos meus pais, irmã e cunhado que me deram todo o suporte que precisei para chegar até a USP, em especial à minha mãe, Ilda, e irmã, Laiza, que sempre incentivaram meus estudos.

Ao meu marido, Vitor, que esteve ao meu lado durante todo o curso, me apoiando nas horas mais complicadas.

Agradeço à minha família de fé do Terreiro de Umbanda Guerreira de Iansã e Guerreiro de Ogum, e à minha mãe e pai de santo, Fabiana e Felipe.

Aos orixás Baiano João Mineiro do Coco, Marinheiro Martino, Capitão dos Sete Remos, e Marinheiro Diogo, Capitão das Sete Âncoras e a todas as entidades da casa que me deram estrutura para enfrentar meus desafios.

À minha madrinha e sogra, Eliana, que sempre me incentivou e me ensinou a enxergar a vida de forma mais leve.

Agradeço a todos os líderes incríveis com quem tive o prazer de trabalhar na área de planejamento de demanda e confiaram no meu trabalho ao longo do curso.

Aos professores da Faculdade de Economia, Administração, Contabilidade e Atuária da Universidade de São Paulo.

E ao meu orientador, Prof. Dr. Claudio Ribeiro de Lucinda, que aceitou me guiar no desenvolvimento desta monografia.

SUMÁRIO

Lista de Tabelas.	VI
Lista de Gráficos.	VIII
Resumo.	IX
Abstract.	X
1. Introdução.	11
2. Mercado de Cosméticos no Brasil.	13
3. Planejamento de Vendas e Operações.	15
4. Coleta de Dados.	16
5. Metodologia.	17
5.1. Metodologia de Cálculo do WMAPE.	17
5.2. Métricas de Performance e Medidas de Erros.	18
6. Modelos de Previsão de Demanda.	19
6.1. Modelos de Suavização Exponencial.	19
6.1.1. Modelos de Suavização Exponencial Simples.	20
6.1.2. Modelo de Holt.	22
6.1.3. Modelo de Holt - Winters.	24
6.1.3.1. Modelo de Holt - Winters Multiplicativo.	25
6.1.3.2. Modelo de Holt - Winters Aditivo.	28
6.2. Modelos de Box - Jenkins.	30
6.2.1. Modelo Autoregressivo (AR)	32
6.2.2. Modelo de Médias Móveis (MA)	33
6.2.3. Modelo Autoregressivo Integrado de Médias Móveis (ARIMA)	33
6.2.4. Aplicação do ARIMA com Sazonalidade (SARIMA)	34
7. Considerações Finais.	42
8. Referências Bibliográficas.	45
9. Apêndices.	47
Apêndice 1. Vendas Históricas da Empresa.	47

LISTA DE TABELAS

Tabela 1 - Principais Mercados Consumidores de HPPC.....	14
Tabela 2 - Previsão de vendas por mês do modelo de Suavização Exponencial Simples.	21
Tabela 3 - Medidas de Erro Modelo Suavização Exponencial Simples.....	21
Tabela 4 - Métricas de Performance - Suavização Exponencial Simples.....	21
Tabela 5 - Parâmetros, Estados Iniciais de Nível e FAC1 - Suavização Exponencial Simples.	21
Tabela 6 - Vendas reais por mês (em unidades)	22
Tabela 7 - WMAPE calculado para modelo de Suavização Exponencial Simples...	22
Tabela 8 - Previsão de vendas por mês do Modelo Holt (em unidades)	23
Tabela 9 - Medidas de Erro do Modelo Holt.	23
Tabela 10 - Métricas de Performance - Modelo de Holt.	23
Tabela 11 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 - Modelo de Holt.	24
Tabela 12 - WMAPE calculado para modelo de Holt.	24
Tabela 13 - Previsão de vendas por mês do Modelo Holt-Winters Multiplicativo....	26
Tabela 14 - Medidas de Erro Modelo de Holt-Winters Multiplicativo.....	26
Tabela 15 - Métricas de Performance - Modelo Holt-Winters Multiplicativo.....	26
Tabela 16 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 - Holt-Winters Multiplicativo	27
Tabela 17a - Estado Inicial - Componente Sazonal $m = 1$ a $m = 6$ - Holt-Winters Multiplicativo	27
Tabela 17b - Estado Inicial - Componente Sazonal $m = 7$ a $m = 12$ - Holt-Winters Multiplicativo	27
Tabela 18 - WMAPE calculado para modelo de Holt-Winters Multiplicativo.....	27
Tabela 19 - Previsão de Vendas por Mês do Modelo Holt-Winters Aditivo.....	29
Tabela 20 - Medidas de Erro Modelo de Holt-Winters Aditivo.....	29
Tabela 21 - Métricas de Performance do Modelo de Holt-Winters Aditivo.....	29
Tabela 22 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 - Holt-Winters Aditivo	29
Tabela 23a - Estado Inicial - Componente Sazonal $m = 1$ a $m = 6$ - Modelo de Holt- Winters Aditivo	29

Tabela 23b - Estado Inicial - Componente Sazonal $m = 7$ a $m = 12$ - Modelo de Holt-Winters Aditivo.	30
Tabela 24 - WMAPE calculado para modelo de Holt-Winters Aditivo.	30
Tabela 25 - Previsão de vendas por mês do Modelo Box-Jenkins.	40
Tabela 26 - Medidas de Erro Modelo de Box-Jenkins	41
Tabela 27 - Métricas de Performance Modelo Box Jenkins.	41
Tabela 28 - Parâmetros Estimados do Modelo Box-Jenkins.	41
Tabela 29 - Erros-Padrão dos Parâmetros Estimados do Modelo Box-Jenkins.	41
Tabela 30 - WMAPE calculado para modelo de Box-Jenkins.	42
Tabela 31 - Quadro Comparativo - Performance dos Modelos Estimados.	42
Tabela 32 - Quadro Comparativo do Critério de Informação de Akaike dos Modelos Estimados.	43
Tabela 33 - Quadro Comparativo do MAPE dos Modelos Estimados.	43

LISTA DE GRÁFICOS

Gráfico 1 - Vendas Totais de Jan/2015 a Dez/2021.	12
Gráfico 2 - Vendas por Categoria de Jan/2015 a Dez/2021.	13
Gráfico 3 - Previsão de vendas do Modelo Holt-Winters Multiplicativo.	26
Gráfico 4 - Previsão de vendas do Modelo Holt-Winters Aditivo.	28
Gráfico 5 - Função de Autocorrelação das séries originais.	35
Gráfico 6 - Função de Autocorrelação Parcial das séries originais.	35
Gráfico 7 - Séries Ajustadas.	37
Gráfico 8 - Função de Autocorrelação das Séries Ajustadas.	37
Gráfico 9 - Função de Autocorrelação Parcial das Séries Ajustadas.	38
Gráfico 10 - Resíduos dos Modelos Estimados.	39
Gráfico 11 - Função de Autocorrelação dos Resíduos.	39
Gráfico 12 - Modelo SARIMA estimado por categoria.	40

RESUMO

VISCOME, Natalia Cruz. **Modelos de previsão de demanda de cosméticos para a indústria varejista brasileira.** 2022. Monografia – Faculdade de Economia, Administração, Contabilidade e Atuária, Universidade de São Paulo, São Paulo, 2022.

Objetivo: indicar para uma fábrica de cosméticos o método de previsão de demanda com melhor assertividade a fim de otimizar a gestão de estoques, reduzindo descartes e impactos ambientais e aumentando o nível de serviço com o cliente final. **Dados:** os dados de vendas históricas foram fornecidos pela empresa e se comportam como séries temporais. **Método:** exploramos duas classes de modelos preditivos, os modelos de suavização exponencial e os modelos de Box-Jenkins e comparamos qual modelo entregou a melhor acuracidade na previsão de acordo com os dados de vendas reais. Calculamos o Erro Percentual Absoluto Médio Ponderado e aplicamos os pesos de acordo com as categorias de produtos mais relevantes para o faturamento da empresa. **Resultados:** de acordo com as séries apresentadas, o modelo com melhor performance foi o de Holt-Winters Multiplicativo, que apresentou uma acuracidade de 86,9%, enquanto o modelo de Box-Jenkins apresentou 70,2% de acuracidade, seguido do modelo Holt-Winters Aditivo com 69,7%. **Conclusão:** devido a melhor performance e a maior facilidade de implementação do modelo na empresa, indicamos o uso do modelo de Holt-Winters Multiplicativo para estimação da demanda de cosméticos.

Palavras-chave: Previsão de Vendas. Gestão de Estoques. Planejamento da Produção. Indústria de Bens de Consumo.

Classificação JEL: C53, L19, D29.

ABSTRACT

VISCOME, Natalia Cruz. **Cosmetics demand forecasting models for Brazilian retail industry**. 2022. Monography – School of Economics, Business Administration and Accounting, University of São Paulo, São Paulo, 2022.

Purpose: indicate to a cosmetics factory the most assertive demand forecasting method with the objective of optimize inventory management, reducing products write off and environmental impacts and increasing service level for the final customer.

Material and Method: historical sales data were provided by the company and behave like time series. We explored two classes of predictive models, exponential smoothing and Box-Jenkins models and compared which model presented the best forecast accuracy in comparison with actual sales data. Then, we calculated Weighted Mean Absolute Percentage Error with weights according to the most relevant categories for the company's revenue. **Results:** the model with best performance was Multiplicative Holt-Winters, which presented an accuracy of 86.9%, while Box-Jenkins model presented 70.2% accuracy, followed by Additive Holt-Winters with 69.7%.

Conclusion: due to the better performance and easier implementation in the company, we indicate the use of the Multiplicative Holt-Winters model to estimate demand for cosmetics.

Key words: Sales forecast. Inventory Management. Production Planning. Consumer Goods Industry.

JEL Classification: C53, L19, D29.

1. INTRODUÇÃO

Esse estudo busca analisar quais os métodos mais eficientes de previsão de demanda para uma empresa varejista de cosméticos no Brasil. Para isso, consolidamos os dados de vendas, em unidades, de janeiro de 2015 até junho de 2022, por mês e por categoria de produto, para vendas realizadas em todos os pontos de venda do território nacional da rede de distribuição da fabricante.


A assertividade da previsão de demanda é importante para o planejamento de produção da indústria, ou seja, com um método eficiente é possível reduzir o descarte de matérias-primas e produtos acabados, sem reduzir o nível de serviço prestado ao consumidor. Nesse contexto, além de ser de grande auxílio para a maximização dos lucros da empresa, a assertividade na previsão também reduz o impacto ambiental da indústria.

Para determinar a assertividade da previsão iremos utilizar o indicador de Erro Percentual Absoluto Médio Ponderado, conhecido pela sigla em inglês como WMAPE, *Weighted Mean Absolute Percentage Error*. Esse indicador calcula a diferença entre o realizado e o planejado, transforma essa diferença em módulo e divide esse valor pelo realizado, esse resultado é o erro percentual absoluto, a partir dele, calcula-se a média ponderada dos erros de todas as categorias analisadas. Tal indicador é muito usado na indústria pois com ele é possível atribuir os pesos de cada medição de acordo com a relevância de cada categoria na empresa. Na seção de metodologia iremos explicar com mais detalhes alguns ajustes necessários nessa métrica para que ela forneça a melhor base para tomadas de decisão da empresa.

Para essa análise, segmentamos os produtos em 6 tipos, adotando como premissa que, dentro de cada categoria, a demanda dos itens indica que são bens perfeitamente substitutos nesse mercado. Além disso, também iremos considerar que o fabricante utiliza o mesmo conjunto de matérias-primas para os produtos dentro de uma mesma categoria, por isso a assertividade na previsão de demanda por categoria auxilia o produtor a realizar uma melhor gestão de estoques de matérias-primas. As categorias abordadas são: Maquiagem, Cuidados Faciais, Cuidados Corporais, Perfumaria, Cuidados Capilares e Higiene Pessoal.

Para comparar a eficiência dos métodos vamos calcular o WMAPE de cada modelo para o período de janeiro de 2022 até junho de 2022. Ou seja, compararemos a previsão de cada modelo para este período com o realizado no período. O modelo

que apresentar menor WMAPE, ou maior assertividade, definida por $1 - \text{WMAPE}$, será considerado o mais eficiente. No gráfico 1 é possível observar o volume de vendas por categoria ao longo dos últimos anos, de acordo com a base de dados de vendas históricas fornecida pela empresa.




Fonte: Elaboração própria a partir das vendas históricas da empresa (2022).

O gráfico 1 indica que o nível de vendas, em geral, apresenta uma leve tendência de crescimento e alta sazonalidade, a qual é marcada pelos chamados “movimentos verticais” de venda do varejo em datas comemorativas, principalmente Natal, e para o setor cosmético, também se observa um segundo pico de vendas em Maio, devido ao Dia das Mães, embora este segundo seja menos intenso que o primeiro.

Percebe-se pelo gráfico 2, o qual segmenta a visualização das vendas por categoria ao longo dos anos, que as séries apresentam comportamentos diferentes por tipo de produto em relação à sazonalidade e tendência, sendo que para algumas categorias é mais fácil de se identificar visualmente essas componentes do que para outras. Isso se dá porque nas vendas reais temos externalidades como rupturas de estoque ou promoções que podem afetar a demanda de categorias específicas de maneira irregular e inesperada.

Gráfico 2 – Vendas por Categoria de Jan/2015 a Dez/2021



Fonte: Elaboração própria a partir das vendas históricas da empresa (2022).

A principal motivação deste estudo é aliar os conceitos e práticas utilizadas atualmente pela empresa aos dados gerados pelos modelos preditivos que serão estimados, e obter a partir das conclusões um direcionamento de qual modelo será mais eficiente para a indústria de cosméticos em análise, levando em consideração aspectos como implementação dos modelos nos processos da empresa. A seguir, abordaremos o contexto do mercado de cosméticos no Brasil para entendermos a relevância desse setor para a economia.

2. MERCADO DE COSMÉTICOS NO BRASIL

O Brasil é um dos mercados mais relevantes para o setor de cosméticos em um contexto global. De acordo com a Associação Brasileira da Indústria de Higiene Pessoal, Perfumaria e Cosméticos (ABIHPEC), em 2018, o país ocupava a 4ª posição no ranking mundial do setor, com uma participação de 6,2% nas movimentações desse mercado, em bilhões de dólares, de acordo com os dados apresentados na Tabela 1.

Além disso, o setor, conhecido pela sigla HPPC, de Higiene Pessoal, Perfumaria e Cosméticos, continua apresentando tendência de crescimento no país, a qual é estimulada pela inovação de novos produtos de beleza que surgem no

mercado e devido a crescente influência de artistas e personalidades do meio digital que movimentam a indústria da beleza.

Tabela 1 - Principais Mercados Consumidores de HPPC

Posição	País	US\$ Bilhões	% participação
1º	Estados Unidos	89,5	18,3
2º	China	62,0	12,7
3º	Japão	37,5	7,7
4º	Brasil	30,3	6,2
5º	Alemanha	20,2	4,1
6º	Reino Unido	18,3	3,6
7º	França	15,3	3,1
8º	Índia	14,1	2,9
9º	Coréia do Sul	13,5	2,9
10º	Itália	11,8	2,4

Fonte: ABIHPEC – Euromonitor (2018)

Dados da ABIHPEC indicam que o setor cresceu 6,5% no primeiro trimestre de 2022 em relação ao mesmo período de 2021 no país. Já em 2020, mesmo durante a pandemia de Covid-19 que afetou o comércio em todo o país, o setor teve crescimento de 5,8% em comparação com o ano anterior em vendas *ex-factory*, ou seja, em faturamento líquido de fábrica. E em 2021 o crescimento foi de cerca de 10% em vendas *ex-factory*, sendo este um dos maiores crescimentos em números absolutos das vendas de cosméticos e demanda por serviços de beleza dos últimos 15 anos, segundo dados da consultoria Mintel divulgados pela empresa Beaty Hair Cosméticos.

Com isso, percebe-se que a indústria de cosméticos possui alto potencial de impacto na economia brasileira, além de também apresentar riscos ambientais se o seu crescimento ocorrer de forma desorganizada nas empresas. Por isso, o estudo aqui proposto visa auxiliar a empresa em questão na tomada de decisões em relação a sua gestão de estoques com base numa previsão de demanda assertiva que possa dar um suporte ao planejamento interno desse crescimento. A seguir iremos abordar os principais aspectos do processo de planejamento de demanda da firma.

3. PLANEJAMENTO DE VENDAS E OPERAÇÕES

O Planejamento de Vendas e Operações, conhecido como S&OP (*Sales and Operations Planning*) é um processo de gerenciamento utilizado por organizações que buscam otimizar o fluxo de tomadas de decisões estratégicas para o negócio. Neste processo ocorre o alinhamento entre as áreas em relação às limitações e expectativas de cada setor, com isso o processo promove melhoria no planejamento de vendas e consequentemente em melhores indicadores de nível de serviço e de qualidade de estoque.

A Sociedade Americana de Controle de Estoque e Produção, APICS (*American Production and Inventory Control Society*) explica o Planejamento de Vendas e Operações como a definição do volume total de produção e outras atividades que melhor atendem ao planejamento de vendas, ao passo que também se preocupam com os objetivos gerais de negócios, como lucratividade, produtividade, prazos de entrega competitivos, entre outros.

O S&OP é dividido em cinco etapas, de acordo com a APICS, que acontecem em um ciclo mensal, sendo a primeira etapa referente à coleta de informações do fechamento do ciclo anterior para atualização das bases de dados. É nesse momento que os volumes de vendas são apurados pelo planejador de demanda para atualização na previsão de vendas dos próximos ciclos.

Na segunda etapa, o planejador estima a demanda irrestrita, ou seja, a capacidade de absorção do mercado pelos produtos ofertados para os próximos ciclos sem restrições da capacidade produtiva da firma. Já na terceira etapa é feita a conciliação dessa demanda com as restrições de oferta. A quarta etapa é a reunião de alinhamento entre os times para validação dos resultados do ciclo anterior e apresentação da previsão de vendas e capacidade produtiva para atendimento dos próximos ciclos.

E, por fim, a quinta etapa é o fórum de S&OP propriamente dito, no qual a diretoria aprova o plano de produção. Portanto, podemos afirmar que uma boa previsão de vendas associada a um bom processo de gerenciamento é capaz de beneficiar diversos indicadores das firmas, sendo eles: o aumento dos níveis de serviço; a redução do capital alocado em estoques; a redução dos descartes de matéria-prima e produto acabado, a redução da ruptura de produtos, e também a otimização da cadeia de suprimentos em termos de custos, estabilidade, tempo de

reação às oscilações de mercado, entre outros.

4. COLETA DE DADOS

Dada a relevância desse tema para o gerenciamento das indústrias, vamos estimar as vendas de acordo com as séries temporais construídas a partir dos dados históricos de vendas em unidades de peças por mês de uma firma que possui planta fabril no Brasil e abastece todo o país a partir de um centro de distribuição único. A firma disponibilizou as informações para este estudo, não sendo, portanto, uma fonte divulgada no meio acadêmico previamente.

Os dados coletados são referentes às vendas de janeiro de 2015 até Junho de 2022, porém a fim de conseguirmos calcular a acuracidade dos modelos, vamos estimar as previsões com os dados somente até dezembro de 2021. Os dados de janeiro de 2022 até junho 2022 serão usados para comparação entre as previsões de cada modelo e a venda real do período.

Esse período que iremos apartar representa 6,67% da base de dados completa disponibilizada pela empresa. Idealmente estimaríamos os modelos com 75% a 90% dos dados, e a parcela de 25% à 10% restante seria utilizada para essa comparação, entretanto tal horizonte de vendas atravessa o período mais intenso da pandemia de Covid-19, que afetou os fluxos do comércio a partir de março de 2020, com efeitos pelo menos até junho de 2021. Portanto, as previsões para esse período tendem a ser menos assertivas devido a essa externalidade.

Nesse estudo, iremos manter o período da pandemia na base de dados, o qual representa cerca de 16% dos dados utilizados e calcular as previsões para o comércio pós-Covid considerando essa externalidade nos modelos. Isso porque queremos entender qual método possui melhor encaixe aos dados mesmo com essa influência. Entendemos que existe uma oportunidade de aprofundamento de estudo também nas questões relacionadas ao efeito da pandemia nas vendas e na acuracidade dos modelos, porém esses tópicos não serão abordados neste estudo.

5. METODOLOGIA

Iremos tratar nossa base de vendas histórica de acordo com os modelos de suavização exponencial simples, dupla (modelo de Holt) e tripla (modelo de Holt-Winters), e também aplicar a metodologia de Box-Jenkins a fim de comparar a performance de cada modelo em relação a melhor assertividade na previsão de vendas. A seguir definiremos algumas métricas importantes para a avaliação dos modelos.

5.1. METODOLOGIA DE CÁLCULO DO WMAPE

O WMAPE, que é o nosso indicador chave de performance dos modelos neste estudo, conforme mencionado anteriormente, calcula a diferença entre o realizado e o planejado, transforma essa diferença em módulo e divide esse valor pelo realizado, esse resultado é o erro percentual absoluto, a partir do qual calcula-se a média ponderada dos erros de todas as categorias analisadas. Os pesos dessa média podem variar de acordo com o objetivo da análise, podendo ser usado o preço ou o custo dos produtos, por exemplo, ou outros pesos arbitrários definidos pelo analista. O cálculo do WMAPE é dado por (Plannera, 2022):

$$\text{WMAPE} = \frac{\sum_{i=0}^n (|Realizado - Previsto| / Realizado) \times Peso}{\sum_{i=0}^n (Peso)}$$

Há uma particularidade matemática na fórmula acima que implica em uma distorção na análise, pois os erros gerados por um volume previsto maior do que o realizado possuem mais impacto na média geral do que os erros gerados pelo realizado ser maior do que o previsto. Isto ocorre pois independente da grandeza do valor realizado, o numerador da fração sempre cresce de acordo com o denominador. Por exemplo, se o realizado for 1000 peças, e o previsto for 1 peça, então o erro absoluto seria de $|1.000-1|/1.000 = 99,9\%$. O erro máximo neste caso será de 100%.

Porém, no caso contrário, é possível assumir erros muito maiores, pois se o previsto for 1000 e o realizado for 1, o erro absoluto então será de $|1-1.000|/1 = 99.900,0\%$. Isto cria uma assimetria de erros que prejudica a interpretação do

indicador. Para corrigir essa distorção iremos aplicar o algoritmo: primeiro, o erro será definido entre -100% e +100%. Segundo, se o volume realizado for zero, mas o previsto for diferente de zero, então o erro será de -100%. Terceiro, se o volume previsto for zero, mas o realizado for diferente de zero, então o erro será de +100%. E, por fim, se os volumes previsto e realizado forem ambos nulos, então o erro será de 0% (Plannera, 2022).

Esse ajuste no cálculo torna o resultado do WMAPE menos abstrato, o que é muito importante dentro de um ciclo de S&OP, pois os resultados de assertividade da previsão são apresentados mensalmente para a diretoria da empresa, na última etapa do processo, e muitas vezes esses profissionais não possuem familiaridade com métricas estatísticas mais sofisticadas, porém serão os responsáveis pelo direcionamento da produção da indústria.

5.2. MÉTRICAS DE PERFORMANCE E MÉTRICAS DE ERROS

Para garantirmos uma exploração mais completa dos modelos estudados, traremos também as métricas de performance AIC (*Akaike's Information Criteria*, ou critério de informação Akaike), AICc (uma versão do AIC corrigida para amostras pequenas) e BIC (*Bayesian information criteria*, ou critério de informação Bayesiano). A métrica AIC foi desenvolvida pelo estatístico japonês Hirotugu Akaike na década de 1970 e o objetivo desse critério de desempenho é penalizar a inclusão de variáveis adicionais ao modelo por meio do aumento do erro quando os termos são adicionados. Quanto menor o valor do AIC, melhor será a qualidade do modelo. E, o critério de informação Bayesiano é uma variação do AIC na qual as penalidades para as inclusões de variáveis adicionais é ainda maior (SAKAMOTO, ISHIGURO e KITAGAWA, 1986).

Em relação às medidas de erro calculadas, traremos primeiramente o valor do erro médio (ME, do inglês *Mean Error*), que nada mais é do que a média da diferença entre o valor total realizado e o total previsto. Porém, nesse cálculo os erros positivos e negativos se anulam, o que pode mascarar a verdadeira dimensão do erro do modelo. Para contornar essa situação, temos o erro médio absoluto (MAE, do inglês *Mean Absolute Error*) que calcula a média do módulo da diferença entre o valor real com o previsto, sendo que essa métrica não é afetada por valores discrepantes, conhecidos como *outliers*. Já o erro percentual absoluto médio (MAPE, do inglês *Mean*

Absolute Percentual Error) é uma métrica que mostra a porcentagem de erro médio absoluto em relação aos valores reais, ou seja, calcula-se o MAE dividido pelo valor realizado.

Também temos o erro quadrático médio (MSE, do inglês *Mean Squared Error*), o qual calcula a média do quadrado da diferença entre o valor predito com o real, assim os valores que são muito diferentes entre o previsto e o real são penalizados. Apesar desse benefício, a métrica MSE apresenta um problema de interpretabilidade, pois ao elevarmos a diferença ao quadrado, a unidade de medida é distorcida.

Desse problema, surge o cálculo da Raiz do Erro Quadrático Médio (RMSE, do inglês *Root Mean Squared Error*), que é basicamente o mesmo cálculo de MSE, a qual também aplica penalização entre grandes diferenças entre o valor previsto e o real. Porém, para lidar com o problema da distorção entre as unidades, é aplicada a raiz quadrada ao cálculo do MSE, assim a unidade do erro permanece igual ao dado original, resultando em uma melhor interpretação da métrica. Para otimizar nossa interpretação iremos ocultar das análises o MSE e exibir apenas o RMSE. E, por fim, além das métricas de acuracidade acima, também temos o erro percentual médio (MPE, do inglês *Mean Percentage Error*), o qual calcula a média dos erros percentuais.

6. MODELOS DE PREVISÃO DE DEMANDA

Existem diversos tipos de modelagem estatística que podem ser aplicadas para a previsão da demanda. Neste estudo focaremos no tratamento de séries temporais, considerando aspectos como tendência e sazonalidade. A seguir vamos abordar com maiores detalhes cada modelo proposto para a comparação.

6.1. MODELOS DE SUAVIZAÇÃO EXPONENCIAL

Os modelos de suavização exponencial são capazes de fornecer previsões a partir de médias ponderadas da série de dados históricos, sendo que normalmente o peso associado a cada observação decresce nas observações mais antigas. Logo, quanto mais recente for o período de tempo da observação, maior será seu peso no modelo preditivo. Esse tipo de modelo é amplamente utilizado no mercado devido a sua relativa simplicidade e bons resultados na acuracidade de previsão.

6.1.1. MODELO DE SUAVIZAÇÃO EXPONENCIAL SIMPLES

O método de suavização exponencial simples é usado para séries que não apresentam tendência, nem sazonalidade, por isso, a previsão para os próximos períodos fica constante. Apesar de termos observado no gráfico 1 que existe tendência e sazonalidade nos nossos dados, iremos calcular as previsões deste modelo para as vendas de cosméticos a fim de comparar com o WMAPE dos demais modelos. O modelo que iremos calcular é do tipo:

$$\hat{Y}_{t+1} = \alpha Y_t + \alpha(1-\alpha) Y_{t-1} + \alpha(1-\alpha)^2 Y_{t-2} + \dots + \alpha(1-\alpha)^n Y_{t-n}$$

Sendo alfa, α , o parâmetro de suavização, o qual assume valores entre 0 e 1 e é o responsável pela atribuição de pesos decrescentes para as observações mais antigas. Quando alfa é igual a 1 chamamos o modelo de ingênuo, pois ele passa a considerar apenas a observação mais recente. O valor ideal de alfa é definido ao minimizar os erros em um conjunto de testes e $n + 1$ é o número de observações históricas consideradas no modelo. (HYNDMAN e ATHANASOPOULOS, 2018). Ou seja, iremos estimar um Y que será o volume de vendas em unidades, em um período futuro $t+1$, $t+2$, ..., $t+h$, para cada categoria de produtos. Nessa análise, queremos estimar as vendas dos próximos 6 meses, com isso $h = 6$. Outra abordagem comum desse modelo é descrevê-lo em forma de componentes, conforme equações a seguir:

$$\hat{Y}_{t+1} = L_t$$

$$L_t = \alpha Y_t + (1-\alpha)L_{t-1}$$

Na suavização exponencial simples só temos a componente de nível, pois esse modelo em sua forma mais simples não trata tendência e sazonalidade, conforme mencionado anteriormente. Apresentando o modelo desta forma percebe-se que é necessário definir os parâmetros alfa e o estado inicial (α e L_0 , respectivamente). Para defini-los iremos assumir que Y_t se comporta como uma curva de distribuição normal de média igual a L_t e variância igual a sigma ao quadrado, σ^2 , e a partir disso estimar os parâmetros via máxima verossimilhança.

Com isso, utilizando a função “ses” do pacote “forecast”, (HYNDMAN e

KHANDAKAR, 2008), obtemos, pelo R a previsão de vendas na Tabela 2 e os resultados de erro, performance e parâmetros e estados iniciais nas tabelas 3, 4 e 5, respectivamente.

Tabela 2 - Previsão de vendas por mês do modelo de suavização exponencial simples (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Higiene Pessoal	71.714	71.714	71.714	71.714	71.714	71.714
Cuidados Corporais	66.895	66.895	66.895	66.895	66.895	66.895
Perfumaria	29.879	29.879	29.879	29.879	29.879	29.879
Cuidados Capilares	25.208	25.208	25.208	25.208	25.208	25.208
Cuidados Faciais	7.966	7.966	7.966	7.966	7.966	7.966
Maquiagem	1.333	1.333	1.333	1.333	1.333	1.333

Fonte: Elaboração própria (2022).

Tabela 3 - Medidas de Erro Modelo Suavização Exponencial Simples

Categoria	ME	RMSE	MAE	MPE	MAPE
Cuidados Corporais	5.605,89	34.430,46	17.614,55	-19,25	45,69
Higiene Pessoal	5.379,11	36.196,66	18.349,05	-16,94	41,20
Cuidados Capilares	384,85	6.904,10	4.407,42	-15,29	41,55
Perfumaria	1.332,28	8.793,89	5.261,19	-12,84	40,74
Cuidados Faciais	180,54	1.613,55	1.118,82	-22,60	55,98
Maquiagem	-0,02	791,51	609,89	-1.622,86	1.647,89

Fonte: Elaboração própria (2022).

Tabela 4 - Métricas de Performance - Suavização Exponencial Simples

Categoria	AIC	AICc	BIC
Cuidados Corporais	2.133,23	2.133,53	2.140,53
Higiene Pessoal	2.141,64	2.141,94	2.148,93
Cuidados Capilares	1.863,29	1.863,59	1.870,58
Perfumaria	1.903,93	1.904,23	1.911,23
Cuidados Faciais	1.619,07	1.619,37	1.626,36
Maquiagem	723,59	724,22	728,81

Fonte: Elaboração própria (2022).

Tabela 5 - Parâmetros, Estados Iniciais de Nível e FAC1 - Suavização Exponencial Simples

Categoria	Alfa	Estado Inicial	Sigma	FAC1
Cuidados Corporais	0,11	13.211,10	34.847,81	0,17
Higiene Pessoal	0,12	18.641,04	36.635,42	0,16
Cuidados Capilares	0,52	8.267,87	6.987,79	0,18
Perfumaria	0,22	5.479,32	8.900,49	0,22
Cuidados Faciais	0,48	660,83	1.633,11	0,16
Maquiagem	0,0001	1.332,7848	811,06	0,21

Fonte: Elaboração própria (2022).

De acordo com a base de dados fornecida, temos o resultado real para o período apresentado na Tabela 6, sendo que os pesos foram calculados pela empresa de acordo com a representatividade de cada categoria no portfólio.

Tabela 6 - Vendas reais por mês (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Pesos WMAPE
Maquiagem	819	3.617	5.665	1.672	8.237	5.158	1
Cuidados Corporais	38.844	33.774	43.912	44.996	75.678	41.252	3
Cuidados Faciais	2.311	2.824	7.088	9.522	7.307	3.884	1
Perfumaria	15.415	14.070	20.735	23.617	34.446	25.094	3
Higiene Pessoal	38.534	37.001	55.202	58.108	78.133	44.220	3
Cuidados Capilares	16.152	11.745	13.743	11.491	13.748	11.659	2

Fonte: Elaboração própria (2022).

Calculando o WMAPE de acordo com a metodologia explicitada anteriormente, temos o resultado consolidado para o período na Tabela 7.

Tabela 7 - WMAPE calculado para modelo de Suavização Exponencial Simples

jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Consolidado Período
79,3%	95,3%	48,8%	41,0%	27,6%	61,9%	49,9%

Fonte: Elaboração própria (2022).

Como a nossa base de dados apresenta tendência, poderíamos diferenciar a série para remover essa tendência e ajustar melhor o modelo aos nossos dados, porém, não vamos focar nessa abordagem neste estudo e partiremos a seguir para a estimação do modelo de suavização exponencial dupla, também conhecido como modelo de Holt, o qual considera a tendência como uma de suas componentes.

6.1.2. MODELO DE HOLT

O Modelo de Holt é uma extensão ao método de suavização exponencial simples, a qual nos permite tratar séries temporais com tendência (HOLT, 1957). Matematicamente, temos:

$$\hat{Y}_{t+h} = L_t + hT_t$$

$$L_t = \alpha Y_t + (1-\alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t - L_{t-1}) + (1-\beta)T_{t-1}$$

Neste modelo, $\hat{Y}_{t+h}$ é a previsão para o período $t+h$, sendo h o número de períodos futuros que queremos estimar a previsão, T_t é a estimaco para o componente de tendncia e L_t é a estimaco do componente de nvel no perodo t . Y_t so os dados observados no perodo t . E os parmetros α e β esto definidos no intervalo $[0,1]$, e podem ser impostos manualmente ou calculados automaticamente por otimizao. O parmetro α é correspondente a suavizao do componente de nvel e o parmetro β corresponde a suavizao do componente de tendncia. Utilizando a funo “holt” do pacote “forecast”, (HYNDMAN e KHANDAKAR, 2008), obtemos, pelo R a previso de vendas na Tabela 8 e os resultados de erro, performance e parmetros e estados iniciais nas tabelas 9, 10 e 11, respectivamente.

Tabela 8 - Previso de vendas por ms do Modelo Holt (Em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Higiene Pessoal	75.543	76.498	77.454	78.410	79.365	80.321
Cuidados Corporais	66.495	67.195	67.894	68.594	69.293	69.993
Cuidados Capilares	25.207	25.381	25.554	25.728	25.901	26.075
Perfumaria	21.862	22.053	22.245	22.436	22.627	22.818
Cuidados Faciais	8.029	8.118	8.208	8.298	8.388	8.477
Maquiagem	1.241	1.232	1.224	1.216	1.207	1.199

Fonte: Elaboraco prpria (2022).

Tabela 9 - Medidas de Erro do Modelo Holt

Categoria	ME	RMSE	MAE	MPE	MAPE
Higiene Pessoal	-2.560,63	35.699,25	21.406,71	-41,33	56,88
Cuidados Corporais	1.098,58	32.988,38	18.078,46	-33,13	52,39
Cuidados Capilares	106,96	6.897,82	4.485,69	-19,23	43,62
Perfumaria	-568,26	8.484,34	5.624,27	-37,81	55,17
Cuidados Faciais	-2,68	1.600,85	1.137,23	-40,98	65,68
Maquiagem	-87,07	807,80	640,75	-1.939,35	1.961,83

Fonte: Elaboraco prpria (2022).

Tabela 10 - Mtricas de Performance - Modelo de Holt

Categoria	AIC	AICc	BIC
Higiene Pessoal	2.143,31	2.144,08	2.155,47
Cuidados Corporais	2.130,05	2.130,82	2.142,20
Cuidados Capilares	1.867,13	1.867,90	1.879,29
Perfumaria	1.901,91	1.902,68	1.914,07
Cuidados Faciais	1.621,74	1.622,51	1.633,90
Maquiagem	729,31	730,97	737,99

Fonte: Elaboraco prpria (2022).

Tabela 11 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 – Modelo de Holt

Categoria	Alfa	Beta	L Inicial	T inicial	Sigma	FAC1
Higiene Pessoal	0,09	0,00	12.194,44	977,10	36.580,85	0,16
Cuidados Corporais	0,0001	0,0001	6.972,93	686,60	33.803,03	0,20
Cuidados Capilares	0,49	0,0005	6.662,82	168,93	7.068,16	0,20
Perfumaria	0,0001	0,0001	5.638,55	196,39	8.693,86	0,27
Cuidados Faciais	0,36	0,0001	530,61	89,76	1.640,38	0,23
Maquiagem	0,0001	0,0001	1.598,0140	-7,9543	849,26	0,22

Fonte: Elaboração própria (2022).

Com base nas vendas reais e nos pesos estabelecidos na tabela 6, obtemos os valores de WMAPE para o modelo indicados na Tabela 12.

Tabela 12 - WMAPE calculado para modelo de Holt

jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Consolidado Período
68,5%	87,2%	44,1%	39,8%	31,5%	66,0%	46,6%

Fonte: Elaboração própria (2022).

Sendo a acuracidade da previsão definida como $1 - \text{WMAPE}$, podemos perceber que com o acréscimo do componente de tendência a acuracidade melhorou em +3,3 pontos percentuais entre o modelo de suavização exponencial simples e o modelo de Holt. Esse resultado era esperado, dado que observamos no gráfico 1 que os dados de vendas históricas possuem tendência e sazonalidade. Como no primeiro modelo não tratamos nenhum desses componentes e neste segundo modelo incluímos a tendência, então foi observada tal melhora no desempenho da acuracidade.

6.1.3. MODELO DE HOLT-WINTERS

O modelo de Holt-Winters (HOLT, 1957 e WINTERS, 1960) é uma evolução do modelo linear de Holt e possibilita o tratamento de séries temporais por suavização exponencial que também possuam um componente sazonal, além da tendência. Esse método possui duas variações, que dependem da natureza do componente sazonal. O primeiro método é o aditivo, o qual é indicado quando as variações sazonais são mais constantes ao longo da série. Já o método multiplicativo é indicado quando as variações sazonais são proporcionais à mudança do nível da série. Esse modelo também é conhecido como método de suavização exponencial tripla, e com ele é possível trabalhar com padrões sazonais mais complexos.

6.1.3.1. MODELO DE HOLT-WINTERS MULTIPLICATIVO

Primeiramente, usaremos neste estudo o método multiplicativo, conforme modelo matemático a seguir:

$$\hat{Y}_{t+h} = (L_t + T_{t-h})S_{t-s+h}$$

$$L_t = \alpha \frac{Y_t}{S_{t-s}} + (1-\alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t + L_{t-1}) + (1-\beta)T_{t-1}$$


$$S_t = \gamma \frac{Y_t}{L_t} + (1-\gamma)S_{t-s}$$

Assim como no modelo de Holt, $\hat{Y}_{t+h}$ é a previsão para o período $t+h$ e definimos T_t como o componente de tendência e L_t como o componente de nível no período t . Acrescentamos neste modelo S_t como componente sazonal. Além disso, “ s ” corresponde ao comprimento da sazonalidade. Os parâmetros α , β e γ estão definidos no intervalo $[0,1]$, e correspondem respectivamente a constante de suavização da componente de nível, a constante de suavização da componente de tendência e a constante de suavização da componente de sazonalidade, tais parâmetros podem ser impostos manualmente ou calculados pelos pacotes estatísticos por otimização de alguns índices, como erro relativo absoluto, por exemplo. Por fim, Y_t corresponde aos dados observados no período t .

Utilizando a função “hw” do pacote “forecast”, (HYNDMAN e KHANDAKAR, 2008) obtemos, pelo sistema estatístico R as previsões indicadas no gráfico 3 e na Tabela 13, para o método multiplicativo. E, nas Tabelas 14, 15, 16 e 17, temos respectivamente os erros do modelo, as métricas de performance, os parâmetros estimados e os estados iniciais.

Na Tabela 18, temos o WMAPE calculado e percebe-se que com o modelo de Holt-Winters multiplicativo conseguimos até agora o melhor WMAPE, lembrando que estamos utilizando essa métrica como fator de decisão de qual modelo implementar na empresa estudada, pois é o indicador que melhor conecta a interpretação do erro com os fatores de tomada de decisão do processo de S&OP, por meio da ponderação das categorias em relação à representatividade de cada uma no portfólio da empresa.

Gráfico 3 – Previsão de vendas do Modelo Holt-Winters Multiplicativo



Fonte: Elaboração própria (2022).

Tabela 13 - Previsão de vendas por mês do Modelo Holt-Winters Multiplicativo (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Higiene Pessoal	56.674	45.696	44.107	44.454	73.389	52.218
Cuidados Corporais	49.001	36.883	36.000	36.774	65.098	43.657
Perfumaria	21.357	17.897	18.139	14.282	26.412	20.651
Cuidados Capilares	14.403	8.625	10.436	10.775	11.655	12.471
Cuidados Faciais	6.700	3.417	2.551	3.133	5.138	3.569
Maquiagem	1.676	1.423	973	717	1.764	1.387

Fonte: Elaboração própria (2022).

Tabela 14 - Medidas de Erro Modelo de Holt-Winters Multiplicativo

Categoria	ME	RMSE	MAE	MPE	MAPE
Higiene Pessoal	137,70	8.738,00	5.208,23	-1,91	14,91
Cuidados Corporais	112,09	9.262,82	6.638,98	-2,68	21,02
Cuidados Capilares	-110,26	3.998,88	2.936,01	-10,55	30,33
Perfumaria	35,12	3.817,31	2.717,21	-6,95	24,58
Cuidados Faciais	116,80	1.203,02	827,02	-15,87	41,27
Maquiagem	-108,21	726,43	560,18	-1.417,29	1.435,87

Fonte: Elaboração própria (2022).

Tabela 15 - Métricas de Performance - Modelo Holt-Winters Multiplicativo

Categoria	AIC	AICc	BIC
Higiene Pessoal	1.905,59	1.914,86	1.946,91
Cuidados Corporais	1.948,42	1.957,69	1.989,74
Cuidados Capilares	1.825,61	1.834,88	1.866,93
Perfumaria	1.769,27	1.778,54	1.810,59
Cuidados Faciais	1.539,28	1.548,56	1.580,61
Maquiagem	739,52	765,02	769,06

Fonte: Elaboração própria (2022).

Tabela 16 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 – Holt-Winters Multiplicativo

Categoria	Alfa	Beta	Gama	L Inicial	T inicial	Sigma	FAC1
Higiene Pessoal	0,44	0,1127	0,0001	16.726,95	604,48	0,26	0,002
Cuidados Corporais	0,34	0,2224	0,0002	9.723,19	617,87	0,39	0,14
Cuidados Capilares	0,81	0,0031	0,0001	8.022,20	173,12	0,54	-0,07
Perfumaria	0,54	0,0001	0,0001	5.875,85	192,48	0,34	-0,03
Cuidados Faciais	0,14	0,0001	0,0004	588,78	37,22	0,51	0,21
Maquiagem	0,01	0,0091	0,0001	1.075,37	26,53	0,63	0,32

Fonte: Elaboração própria (2022).

Tabela 17a - Estado Inicial - Componente Sazonal m = 1 a m = 6 – Holt-Winters Multiplicativo

Categoria	Si m = 1	Si m = 2	Si m = 3	Si m = 4	Si m = 5	Si m = 6
Higiene Pessoal	3,32	1,23	0,86	0,78	0,78	0,69
Cuidados Corporais	3,35	1,31	0,86	0,69	0,70	0,84
Cuidados Capilares	2,09	1,53	0,89	1,06	0,78	1,01
Perfumaria	2,44	1,34	0,85	0,88	0,83	0,82
Cuidados Faciais	1,88	1,26	1,41	1,13	1,19	1,03
Maquiagem	1,00	1,26	0,50	0,67	0,96	1,12

Fonte: Elaboração própria (2022).

Tabela 17b - Estado Inicial - Componente Sazonal m = 7 a m = 12– Holt-Winters Multiplicativo

Categoria	Si m = 7	Si m = 8	Si m = 9	Si m = 10	Si m = 11	Si m = 12
Higiene Pessoal	0,66	0,96	0,60	0,61	0,65	0,83
Cuidados Corporais	0,69	1,03	0,58	0,58	0,59	0,79
Cuidados Capilares	0,82	0,78	0,73	0,71	0,59	0,10
Perfumaria	0,83	1,06	0,58	0,74	0,74	0,89
Cuidados Faciais	0,59	0,85	0,52	0,43	0,58	1,14
Maquiagem	1,20	0,88	1,39	0,84	1,12	1,05

Fonte: Elaboração própria (2022).

Tabela 18 - WMAPE calculado para modelo de Holt-Winters Multiplicativo

jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Consolidado Período
42,8%	24,2%	26,7%	29,3%	20,7%	16,9%	13,1%

Fonte: Elaboração própria (2022).

Considerando assertividade como 1 - WMAPE, neste modelo temos um ganho de assertividade de +33,6 pontos percentuais em relação ao modelo de Holt. Tal desempenho é devido ao acréscimo do fator de sazonalidade, o qual se adapta melhor aos dados históricos apresentados.

6.1.3.2. MODELO DE HOLT-WINTERS ADITIVO

Para esse tratamento, modelamos nossas séries conforme modelo matemático a seguir, com os mesmos parâmetros e variáveis do modelo multiplicativo, porém interagindo agora em relações aditivas:

$$\hat{Y}_{t+h} = L_t + T_{t-h} + S_{t-s+h}$$


$$L_t = \alpha(Y_t + S_{t-s}) + (1-\alpha)(L_{t-1} + T_{t-1})$$

$$T_t = \beta(L_t + L_{t-1}) + (1-\beta)T_{t-1}$$

$$S_t = \gamma(Y_t + L_t) + (1-\gamma)S_{t-s}$$

Com base no modelo descrito acima, obtemos os resultados de previsão ilustrados no gráfico 4, e descritos na Tabela 19. Na tabela 20 temos os erros do modelo, já as medidas de performance, os parâmetros e os estados iniciais estão indicados nas Tabelas 21, 22 e 23.

Gráfico 4 – Previsão de vendas do Modelo Holt-Winters Aditivo



Fonte: Elaboração própria (2022).

Tabela 19 - Previsão de Vendas por Mês do Modelo Holt-Winters Aditivo (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Higiene Pessoal	84.322	82.042	82.292	80.446	96.095	82.782
Cuidados Corporais	46.629	42.248	35.312	40.665	70.001	54.503
Perfumaria	25.641	23.727	24.284	23.312	29.630	25.439
Cuidados Capilares	19.835	14.321	17.202	16.459	17.029	16.783
Cuidados Faciais	6.576	5.735	5.968	5.558	6.219	6.530
Maquiagem	1.045	1.011	372	122	1.309	882

Fonte: Elaboração própria (2022).

Tabela 20 - Medidas de Erro Modelo de Holt-Winters Aditivo

Categoria	ME	RMSE	MAE	MPE	MAPE
Higiene Pessoal	837,20	14.247,45	8.417,08	-2,02	24,60
Cuidados Corporais	-246,32	14.023,04	9.259,65	-9,21	32,47
Cuidados Capilares	-93,75	5.261,51	3.789,17	-11,71	40,25
Perfumaria	156,15	5.020,32	3.429,96	-7,69	32,47
Cuidados Faciais	52,26	1.199,54	805,13	-7,30	46,29
Maquiagem	-131,06	730,15	549,95	-1.567,27	1.584,48

Fonte: Elaboração própria (2022).

Tabela 21 - Métricas de Performance do Modelo de Holt-Winters Aditivo

Categoria	AIC	AICc	BIC
Higiene Pessoal	2.013,00	2.022,27	2.054,32
Cuidados Corporais	2.010,33	2.019,60	2.051,65
Cuidados Capilares	1.845,64	1.854,91	1.886,97
Perfumaria	1.837,76	1.847,03	1.879,08
Cuidados Faciais	1.597,26	1.606,53	1.638,58
Maquiagem	744,81	770,31	774,35

Fonte: Elaboração própria (2022).

Tabela 22 - Parâmetros, Estados Iniciais de Nível e Tendência e FAC1 - Holt-Winters Aditivo

Categoria	Alfa	Beta	Gama	L Inicial	T inicial	Sigma	FAC1
Higiene Pessoal	0,41	0,0001	0,0001	24.658,36	498,80	15.835,15	0,041
Cuidados Corporais	0,19	0,0001	0,7314	16.951,32	629,36	15.585,73	0,22
Cuidados Capilares	0,40	0,0001	0,0001	9.130,68	150,78	5.847,84	0,17
Perfumaria	0,27	0,0001	0,0001	7.986,69	192,33	5.579,77	0,12
Cuidados Faciais	0,28	0,0013	0,0003	910,69	57,00	1.333,22	0,23
Maquiagem	0,02	0,0179	0,0081	1.014,21	39,94	928,00	0,30

Fonte: Elaboração própria (2022).

Tabela 23a - Estado Inicial - Componente Sazonal m = 1 a m = 6 - Modelo de Holt-Winters Aditivo

Categoria	Si m = 1	Si m = 2	Si m = 3	Si m = 4	Si m = 5	Si m = 6
Higiene Pessoal	94.413,89	11.222,33	-4.578,00	-8.895,09	-8.222,14	-10.440,77
Cuidados Corporais	90.106,47	11.139,10	-5.863,66	-9.536,91	-10.382,86	-9.863,23
Cuidados Capilares	11.588,50	6.153,96	-1.948,59	-1.049,15	-1.822,19	195,72
Perfumaria	19.055,25	5.297,35	-1.460,22	-1.574,24	-2.117,92	-1.372,60
Cuidados Faciais	3.088,74	763,81	70,38	-300,48	566,43	401,65
Maquiagem	61,21	428,48	-818,15	-626,21	-43,53	-74,53

Fonte: Elaboração própria (2022).

Tabela 23b - Estado Inicial - Componente Sazonal $m = 7$ a $m = 12$ - Modelo de Holt-Winters Aditivo

Categoria	Si $m = 7$	Si $m = 8$	Si $m = 9$	Si $m = 10$	Si $m = 11$	Si $m = 12$
Higiene Pessoal	-15.395,98	-1.575,64	-16.719,44	-14.367,38	-14.110,91	-11.330,87
Cuidados Corporais	-12.965,43	2.097,03	-14.632,74	-15.281,32	-14.183,34	-10.633,11
Cuidados Capilares	-2.716,79	-2.320,15	-2.740,10	-1.846,97	-4.578,98	1.084,75
Perfumaria	-3.354,78	1.029,68	-5.095,01	-3.928,81	-4.291,94	-2.186,76
Cuidados Faciais	-489,28	-737,62	-1.336,39	-862,84	-1.033,36	-131,05
Maquiagem	506,83	-45,60	478,50	-367,01	265,51	234,49

Fonte: Elaboração própria (2022).

Tabela 24 - WMAPE calculado para modelo de Holt-Winters Aditivo

jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Consolidado
56,3%	61,3%	32,1%	28,4%	21,6%	46,2%	30,3%

Fonte: Elaboração própria (2022).

De acordo com o resultado do WMAPE das tabelas 18 e 24, concluímos que o modelo multiplicativo é mais eficiente no ajuste dos dados do que o modelo aditivo, o que indica que a sazonalidade varia conforme o nível das nossas séries. Além disso, os resultados das tabelas 14, 15, 20 e 21 também são coerentes com essa conclusão.

6.2. MODELOS DE BOX-JENKINS

Os modelos ARIMA foram sistematizados na década de 1970 por George Box e Gwilym Jenkins e a sigla advém do inglês *Auto Regressive Integrated Moving Average*, ou Modelos Autoregressivos Integrados à Média Móvel, os quais descrevem a autocorrelação existente entre os valores da série temporal analisada e, com base nisso, obtêm as previsões para os períodos seguintes. Já os modelos de suavização exponencial vistos até então são baseados em descrever os componentes de nível, tendência e sazonalidade da série.

De acordo com os autores Rob Hyndman e George Athanasopoulos, da Universidade de Monash, na Austrália, os modelos ARIMA, por essa diferença na metodologia, nos fornecem abordagens complementares a esse tipo de problema para a previsão de séries temporais, sendo que, ainda de acordo com os autores, os modelos de suavização exponencial e os modelos ARIMA são as duas classes de modelagens mais usadas para essa finalidade preditiva.

Em geral, os modelos ARIMA representam as séries temporais como uma sequência de choques aleatórios submetidos a três operações de filtragem: auto-

regressiva (AR), de integração (I), e médias-móveis (MA), sendo que as séries podem ser modeladas por todos esses filtros ou pelos subconjuntos deles, o que gera uma grande diversidade de modelos resultantes possíveis (FAVA, 2000).

Para a construção dos modelos ARIMA, o método de Box-Jenkins determina a aplicação das seguintes etapas: primeiramente, temos a identificação do modelo, que corresponde à determinação do nível de diferenciação (d), a partir do qual a série se torna estacionária; da ordem dos termos autoregressivos (p); e da ordem dos termos médias-móveis (q). Essas determinações são obtidas a partir da análise das funções de autocorrelação e de autocorrelação parcial, que abordaremos a seguir.

A função de autocorrelação, FAC, mede a correlação entre o valor de um período e o valor da defasagem, essa função pode ser usada para estimar a ordem do MA(q). Já a função de autocorrelação parcial, PACF (do inglês *Partial Autocorrelation Function*), elimina as correlações acumuladas entre a variável e suas defasagens, ou seja, a PACF calcula a correlação entre o valor observado em t e o valor observado em t-k após remover os efeitos intermediários das defasagens que existem entre o período 1 e o período k-1. Com isso, é possível estimar a ordem do AR(p). E, para estimarmos a ordem de integração I(d), além da análise da FAC e da PACF, também realizamos testes de raiz unitária para determinar se a série é estacionária ou não, e diferenciamos a série até que o teste indique que existe estacionariedade (MAKRIDAKIS et al., 1998).

Após a identificação, ou seja, determinada a ordem (p, d, q) do modelo, são estimados os seguintes parâmetros: μ , o nível do processo também conhecido como ruído branco; os parâmetros auto-regressivos ϕ_1, ϕ_2 , até ϕ_p ; os parâmetros médias-móveis θ_1, θ_2 , até θ_q ; e (σ^2) , a variância do ruído branco. Em seguida temos a etapa de validação, na qual os erros calculados, como MAPE e MSE, são avaliados juntamente com a aleatoriedade dos resíduos do modelo, indicada nas funções de autocorrelação. E por fim, temos a construção da função de previsão. (MAKRIDAKIS et al., 1998).

Vale ressaltar que Box e Jenkins sugerem a utilização parcimoniosa desses modelos, ou seja, a utilização com o menor número possível de parâmetros, em virtude do teorema da dualidade, o qual não iremos explorar neste estudo. Além disso, outra condição importante para utilizar os modelos de Box-Jenkins é que eles são usados com séries estacionárias, ou seja, séries nas quais suas propriedades como

média e variância, entre outras, não dependem do período da observação. Logo, séries com tendência ou sazonalidade não são estacionárias. Para contornar esse problema, conforme mencionado anteriormente, diferenciamos as séries até que se tornem estacionárias. Sendo que normalmente apenas uma diferenciação já se mostra suficiente para gerar a estacionariedade (MAKRIDAKIS et al., 1998).

A seguir, iremos explorar com maiores detalhes cada componente do modelo ARIMA antes de finalmente aplicarmos a metodologia de Box-Jenkins aos nossos dados para calcularmos as previsões.

6.2.1. MODELO AUTOREGRESSIVO (AR)

Os modelos auto-regressivos, AR(p), utilizam uma regressão para determinar o valor da variável de interesse em um período futuro partindo dos valores dos períodos anteriores como base, como se fossem as variáveis explicativas, ou seja, aplica-se uma autoregressão defasada em p períodos, enquanto a correlação entre os valores desses períodos for significativa (HYNDMAN e ATHANASOPOULOS, 2018). Portanto, os valores futuros da série dependem diretamente dos valores nos períodos passados. O modelo autorregressivo de ordem p é expresso matematicamente como a seguir:

$$Z_t = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \mu_t$$

Sendo que p é a ordem do AR, Z_t é o valor da série observado no período t, μ_t é o ruído branco, ou seja, é o termo de erro aleatório, sem correlação com Z e com média zero e variância constante. E por fim, ϕ_p são os coeficientes autorregressivos, ou seja, os parâmetros que descrevem matematicamente como o valor atual se relaciona com seus valores passados, e podem ser estimados pelo método dos mínimos quadrados ordinários.

De acordo com a metodologia de Box-Jenkins, para verificarmos o número de defasagens ideal podemos nos guiar pelos critérios de informação de Akaike, já explicados na seção de metodologia, ou analisar os valores da função de autocorrelação parcial.

6.2.2. MODELO DE MÉDIAS MÓVEIS (MA)

Os modelos de médias móveis, MA(q), apresentam os valores de cada observação da série como uma combinação linear do valor do período atual com os resíduos aleatórios de previsões dos períodos passados. Esses modelos são gerados pela média ponderada dos erros aleatórios de defasagem q, conforme podemos observar na equação abaixo:

$$Z_t = \mu_t - \theta_1 \mu_{t-1} - \theta_2 \mu_{t-2} - \dots - \theta_q \mu_{t-q}$$

Neste modelo, além das variáveis já definidas anteriormente, consideramos q como a ordem do MA e θ_q como os parâmetros do modelo (HYNDMAN e ATHANASOPOULOS, 2018).

6.2.3. MODELO AUTOREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS (ARIMA)

Normalmente, as séries temporais que encontramos em economia não são estacionárias, ou seja, não são integradas. Entretanto, conforme mencionado anteriormente, quando esbarramos nesse problema ao aplicar a metodologia de Box-Jenkins podemos diferenciar os dados até que essa série se torne estacionária.

Lembrando que a estacionariedade se dá quando as propriedades estatísticas da série, como média, variância e covariância são constantes ao longo dos períodos, ou seja, uma série estacionária é aquela cujas propriedades não dependem do período em que o valor é observado, portanto, séries que contenham tendência ou sazonalidade não são estacionárias, pois essas características afetam as propriedades da série ao longo dos períodos. Esse problema, por outro lado, não é observado na componente de ruído branco, pois este não apresenta tendência nem sazonalidade.

Com isso, em um modelo ARIMA, além das componentes descritas nos modelos AR(p) e MA(q), será incluída uma componente de integração I(d), a qual é responsável por descrever o número de vezes que a série precisa ser diferenciada até se tornar estacionária, esse número é a definição do parâmetro d. Portanto, temos como resultado o modelo Autorregressivo Integrado de Médias Móveis, ARIMA(p,d,q), sendo que, se d = 0, então a série é estacionária sem necessidade de

diferenciação, neste caso estaremos tratando de um modelo também chamado de ARMA(p,q). A seguir, temos as equações do modelo:

$$Z_t = AR(p) + I(d) + MA(q)$$

$$AR(p) = \phi_1 Z_{t-1} + \phi_2 Z_{t-2} + \dots + \phi_p Z_{t-p} + \mu_t$$

$$MA(q) = \mu_t - \theta_1 \mu_{t-1} - \theta_2 \mu_{t-2} - \dots - \theta_q \mu_{t-q}$$

$$I(d) = Z_t - Z_{t-1}, \text{ se } d = 1$$

Percebe-se que esse modelo ainda não está adaptado para tratamento de séries com sazonalidade, pois a diferenciação apenas corrige a tendência. A fim de otimizarmos nosso estudo, iremos estimar as previsões da metodologia de Box-Jenkins a partir do tópico a seguir, no qual incluiremos na modelagem o componente de sazonalidade.


6.2.4. APLICAÇÃO DO ARIMA COM SAZONALIDADE

O ARIMA com sazonalidade é conhecido como SARIMA, do inglês *Seasonal Autoregressive Integrated Moving Average*, e é uma extensão do modelo tratado até aqui para inclusão da componente de sazonalidade. No SARIMA, as componentes AR(p), I(d) e MA(q) continuam como visto anteriormente e é adicionado a componente de notação (P,D,Q)_m, resultando no modelo SARIMA(p,d,q) x (P,D,Q)_m, no qual m é o número de períodos sazonais dentro do ano, por exemplo, se m = 12, então a sazonalidade é mensal, se m = 3, então a sazonalidade é por trimestre, etc.

Utilizamos a notação em letras minúsculas para a parte não sazonal do modelo, e a notação em letras maiúsculas para a parte sazonal. Assim como no ARIMA, os valores de P, D e Q podem ser obtidos através da análise das funções de autocorrelação e de autocorrelação parcial.


Agora que explicamos o modelo de Box-Jenkins com mais detalhes, iremos aplicar sua metodologia à nossa base de dados para estimar as previsões de demanda por categoria. Primeiramente, vamos analisar nos gráficos 5 e 6 as funções de autocorrelação e autocorrelação parcial das séries, para entendermos a necessidade de diferenciação.

Gráfico 5 – Função de Autocorrelação das séries originais



Fonte: Elaboração própria (2022).

Gráfico 6 – Função de Autocorrelação Parcial das séries originais



Fonte: Elaboração própria (2022).

Para a categoria de maquiagem, conforme observado no gráfico 2 da introdução, percebemos que nossa base de dados não possui valores para o período entre final de 2016 e meados de 2018, portanto, para conseguirmos aplicar a metodologia nesta categoria iremos utilizar os dados de 2019 em diante. Ainda com base no gráfico 2, percebemos que todas as demais categorias parecem apresentar

uma certa tendência, mas apresentam uma sazonalidade mais explícita, com exceção da categoria de Maquiagem. E os resultados da FAC e da PACF apresentados acima também são coerentes com essa conclusão, nos levando a assumir que para todas as categorias exceto Maquiagem é provável que seja necessário diferenciar os dados a fim de alcançarmos a estacionariedade.

A análise gráfica e a análise das funções de autocorreção realizadas até então não são o suficiente para indicar quantas diferenciações serão necessárias para tornar as séries estacionárias, a fim de obtermos essa resposta, executaremos os testes de raiz unitária e apesar da função de autocorrelação da categoria de Maquiagem ter indicado que pode haver estacionariedade, também é necessário executar os testes para essa categoria para garantirmos a significância dos indicadores de estacionariedade.


Para o teste de estacionariedade da parte não sazonal da série utilizamos o teste de Kwiatkowski, Phillips, Schmidt e Shin, conhecido como KPSS, (KWIATKOWSKI et al, 1992), no qual a hipótese nula é que a série analisada apresenta uma raiz estacionária, e a hipótese alternativa é que a série possui raiz unitária, logo não é estacionária, essa aplicação também indica o número de diferenças necessárias para aceitarmos a hipótese nula ao nível de 95% de confiança. Existem diversos tipos de testes disponíveis para avaliação das raízes unitárias, porém não iremos explorar maiores detalhes sobre esse tópico neste estudo.

De acordo com o resultado do teste executado acima, concluímos com 95% de significância que todas as nossas categorias necessitam de uma diferenciação para alcançar a estacionariedade, exceto a categoria de Maquiagem, que realmente já é estacionária. Além disso, para deixarmos a variância constante, além da primeira diferenciação é necessário aplicar o logaritmo natural aos valores das séries, essa parte também será aplicada à categoria de Maquiagem, que apresenta variância decrescente ao longo da série. Já em relação a parte sazonal das séries, aplicamos o teste de raiz unitária sazonal para determinar o número de diferenciações sazonais necessárias para a estacionariedade.

Neste teste, de acordo com Wang, Smith & Hyndman, uma medida de força sazonal é usada, na qual a diferenciação é indicada se essa força sazonal for superior à 0,64, com base na minimização do erro médio escalonado absoluto, ou MASE, do inglês *Mean Absolute Scaled Error*, que se trata do MAE do modelo dividido pelo MAE de um modelo simples, o qual estima o valor futuro replicando o valor histórico anterior,


ou seja, o MASE compara o modelo estudado com o modelo simples, de forma que se o MASE for maior que 1, então o modelo é pior do que o modelo simples. De acordo com o resultado do teste de estacionariedade sazonal, se mostrou necessária a diferenciação da parte sazonal das categorias de Cuidados Corporais, Perfumaria e Higiene Pessoal. Com todos os ajustes realizados, as séries passaram a apresentar o comportamento observado no gráfico 7, com as funções de autocorrelação e autocorrelação parcial indicadas nos gráficos 8 e 9 respectivamente.

Gráfico 7 – Séries Ajustadas




Fonte: Elaboração própria (2022).

Gráfico 8 – Função de Autocorrelação das Séries Ajustadas



Fonte: Elaboração própria (2022).

Gráfico 9 – Função de Autocorrelação Parcial das Séries Ajustadas




Fonte: Elaboração própria (2022).

A partir da análise da Função de Autocorrelação, FAC e da função de autocorrelação parcial, PACF das séries ajustadas, identificamos os possíveis valores para determinar a ordem dos modelos, ou seja, os valores de (p,d,q) e $(P,D,Q)_m$, e validamos os valores identificados com 95% de significância.

Para a etapa de estimação dos parâmetros de ruído branco (μ), auto-regressivos $(\phi_1, \phi_2, \dots, \phi_p)$, de médias-móveis $(\theta_1, \theta_2, \dots, \theta_q)$ e da variância do ruído branco (σ^2), utilizamos neste estudo a função “autoarima” do pacote forecast do R, a qual utiliza uma variação da metodologia desenvolvida pelos autores Hyndman e Khandakar, em 2008, que calcula testes de estacionariedade, otimização dos critérios de informação de Akaike e de erros para obter os parâmetros do modelo ARIMA.


Após as etapas de identificação e estimação, agora vamos para a etapa de validação dos modelos encontrados. Analisaremos os resíduos para verificação de existência de *outliers* ou evidências de períodos que não se ajustaram satisfatoriamente aos dados. É importante que os resíduos do modelo, indicados no gráfico 10, não sejam correlacionados ao longo do tempo, para isso, traremos os gráficos da FAC dos resíduos para analisar visualmente essa correlação, no gráfico 11.

Gráfico 10 – Resíduos dos Modelos Estimados



Fonte: Elaboração própria (2022).

Gráfico 11 – Função de Autocorrelação dos Resíduos



Fonte: Elaboração própria (2022).


Pelos gráficos 10 e 11, temos um indicativo de que os resíduos não são correlacionados entre si ao longo das defasagens e possuem média zero e variância constante, conforme esperado. Algumas categorias se ajustaram melhor do que outras, e também conseguimos perceber que a queda na demanda devido à pandemia da Covid-19 em 2020 perturbou os dados, afetando a qualidade do nosso ajuste, principalmente na categoria de Cuidados Corporais e Higiene Pessoal.

Como oportunidade de estudos futuros podemos explorar com mais detalhes

esse fator e remodelar as séries para alcançarmos uma qualidade melhor no ajuste, porém, não iremos estender essa exploração neste estudo pois nosso intuito é termos um panorama mais generalizado de comparação entre os modelos de suavização exponencial e de Box-Jenkins. E, além da análise dos resíduos também é possível explorar diversos algoritmos existentes para testar a normalidade, a correlação, entre outros aspectos dos resíduos a fim de garantir a melhor qualidade do ajuste, porém também não iremos abordar tais testes aqui, dado que já temos uma função de autocorrelação indicando com bom grau de significância que não existe correlação entre as defasagens das séries.

Com isso, temos, de acordo com o gráfico 12 e com a Tabela 25, as previsões de vendas para o ano de 2022 de acordo com a metodologia aplicada de Box-Jenkins. E, nas tabelas 26, 27, 28 e 29 temos respectivamente, os erros do modelo, as métricas de performance, os parâmetros estimados, e os erros-padrão dos parâmetros estimados.

Gráfico 12 – Modelo SARIMA estimado por categoria



Fonte: Elaboração própria (2022).

Tabela 25 - Previsão de vendas por mês do Modelo Box-Jenkins (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Higiene Pessoal	63.208	49.191	42.957	38.022	66.722	48.186
Cuidados Corporais	50.473	39.160	31.898	30.931	62.436	44.995
Cuidados Capilares	23.021	17.264	23.372	21.527	24.144	26.111

Tabela 25 - Previsão de vendas por mês do Modelo Box-Jenkins (em unidades)

Categoria	jan/22	fev/22	mar/22	abr/22	mai/22	jun/22
Perfumaria	19.582	14.340	12.205	11.139	20.923	14.947
Cuidados Faciais	3.435	1.757	1.995	1.420	2.439	3.065
Maquiagem	1.381	1.225	1.160	1.132	1.120	1.114

Fonte: Elaboração própria (2022).

Tabela 26 - Medidas de Erro Modelo de Box-Jenkins

Categoria	ME	RMSE	MAE	MPE	MAPE
Higiene Pessoal	0,00	0,20	0,14	-0,03	1,34
Cuidados Corporais	-0,02	0,23	0,15	-0,16	1,49
Cuidados Capilares	0,01	0,39	0,30	0,00	3,26
Perfumaria	0,06	0,30	0,20	0,66	2,14
Cuidados Faciais	0,09	0,39	0,30	1,12	3,88
Maquiagem	0,01	0,54	0,43	-0,40	6,19

Fonte: Elaboração própria (2022).

Tabela 27 - Métricas de Performance Modelo Box Jenkins

Categoria	AIC	AICc	BIC
Higiene Pessoal	-7,03	-6,86	-2,51
Cuidados Corporais	14,97	15,15	19,49
Cuidados Capilares	91,10	91,41	98,36
Perfumaria	49,49	49,84	56,32
Cuidados Faciais	91,20	91,56	98,03
Maquiagem	64,16	64,91	68,91

Fonte: Elaboração própria (2022).

Tabela 28 - Parâmetros Estimados do Modelo Box-Jenkins

Categoria	AR(1)	MA(1)	SAR(1)	SMA(1)	Média
Higiene Pessoal	-	-	-	-0,63	-
Cuidados Corporais	-	-	-	-0,61	-
Cuidados Capilares	-	0,50	0,50	-	-
Perfumaria	0,79	-	-	-0,45	-
Cuidados Faciais	0,80	-	-	-0,52	-
Maquiagem	0,45	-	-	-	7,01

Fonte: Elaboração própria (2022).

Tabela 29 - Erros-Padrão dos Parâmetros Estimados do Modelo Box-Jenkins

Categoria	E.P. AR(1)	E.P. MA(1)	E.P. SAR(1)	E.P. SMA(1)	E.P. Média	σ^2
Higiene Pessoal	-	-	-	0,16	-	0,05
Cuidados Corporais	-	-	-	0,14	-	0,06
Cuidados Capilares	-	0,16	0,10	-	-	0,16
Perfumaria	0,07	-	-	0,13	-	0,10
Cuidados Faciais	0,08	-	-	0,15	-	0,18
Maquiagem	0,15	-	-	-	0,16	0,31

Fonte: Elaboração própria (2022).

Tabela 30 - WMAPE calculado para modelo de Box-Jenkins

jan/22	fev/22	mar/22	abr/22	mai/22	jun/22	Consolidado Período
43,5%	26,9%	43,3%	49,8%	39,9%	36,5%	29,8%

Fonte: Elaboração própria (2022).

Apesar de ter obtido um WMAPE melhor do que o modelo de Holt-Winters aditivo, conforme observado na Tabela 30, o modelo de Box-Jenkins estimado não superou a performance do Holt-Winters multiplicativo.

7. CONSIDERAÇÕES FINAIS

Com base nos resultados apresentados anteriormente, temos na tabela 31 um resumo do WMAPE e da acuracidade, ou seja, 1 - WMAPE de cada modelo. E, podemos concluir que neste estudo o modelo de Holt-Winters Multiplicativo desempenhou a melhor acuracidade de previsão no nosso teste de comparação dos valores previstos com as vendas reais do período de janeiro a junho de 2022.

Tabela 31 – Quadro Comparativo - Performance dos Modelos Estimados

Modelo	WMAPE	Acuracidade
Holt-Winters Multiplicativo	13,1%	86,9%
Box-Jenkins	29,8%	70,2%
Holt-Winters Aditivo	30,3%	69,7%
Holt	46,6%	53,4%
Suavização Exponencial Simples	49,9%	50,1%

Fonte: Elaboração própria (2022).

Entretanto, de acordo com a tabela 32, o modelo da metodologia aplicada de Box-Jenkins performou muito melhor em termos dos critérios de informação de Akaike. Além disso, a aplicação do SARIMA também performou melhor de acordo com o MAPE estimado pelo pacote “forecast”, conforme observado na Tabela 33, com base nos dados até dezembro de 2021, ou seja, sem comparar com as vendas reais igual fizemos no cálculo do WMAPE.

Outro ponto de atenção é que em todos os modelos, a categoria de Maquiagem apresenta o pior MAPE, isso é devido à baixa qualidade na série temporal utilizada para a estimação, pois de acordo com o gráfico 2 a série apresenta muitas externalidades e é mais inconstante do que as demais. Como no modelo de Box-Jenkins limpamos a base de Maquiagem para excluir o período sem vendas, então a

discrepância entre o MAPE dessa categoria e das demais é menor do que nos outros modelos, nos quais não alteramos a base de dados para calcular as estimações.

Tabela 32 – Quadro Comparativo do Critério de Informação de Akaike dos Modelos Estimados

Categoria	Suavização Exponencial Simples	Holt	Holt-Winters Multiplicativo	Holt-Winters Aditivo	Box-Jenkins (SARIMA)
Cuidados Corporais	2.133,23	2.130,05	1.948,42	2.010,33	14,97
Higiene Pessoal	2.141,64	2.143,31	1.905,59	2.013,00	-7,03
Cuidados Capilares	1.863,29	1.867,13	1.825,61	1.845,64	91,10
Perfumaria	1.903,93	1.901,91	1.769,27	1.837,76	49,49
Cuidados Faciais	1.619,07	1.621,74	1.539,28	1.597,26	91,20
Maquiagem	723,59	729,31	739,52	744,81	64,16
Média Simples	1.730,79	1.732,24	1.621,28	1.674,80	50,65

Fonte: Elaboração própria (2022)

Tabela 33 – Quadro Comparativo do MAPE dos Modelos Estimados

Categoria	Suavização Exponencial Simples	Holt	Holt-Winters Multiplicativo	Holt-Winters Aditivo	Box-Jenkins (SARIMA)
Cuidados Corporais	45,69	52,39	21,02	32,47	1,49
Higiene Pessoal	41,20	56,88	14,91	24,60	1,34
Cuidados Capilares	41,55	43,62	30,33	40,25	3,26
Perfumaria	40,74	55,17	24,58	32,47	2,14
Cuidados Faciais	55,98	65,68	41,27	46,29	3,88
Maquiagem	1.647,89	1.961,83	1.435,87	1.584,48	6,19
Média Simples	312,18	372,60	261,33	293,43	3,05

Fonte: Elaboração própria (2022)

Além dos pontos discutidos acima, também é possível observar pelo gráfico 3, que contém as previsões do modelo Holt-Winters Multiplicativo, que a variância das previsões neste modelo é heterocedástica, ou seja, é inconstante, neste caso, aparenta aumentar ao longo do horizonte de previsão, diferentemente dos modelos Holt-Winters Aditivo e de Box-Jenkins, observados nos gráficos 4 e 12, respectivamente. Neste último, porém, a categoria de Cuidados Capilares também apresenta heterocedasticidade, porém de forma mais contida do que no modelo Holt-Winters Multiplicativo.

Esse resultado está relacionado à sazonalidade crescente ao longo dos anos e às externalidades, como a queda nas vendas durante o período de pandemia da Covid-19, que poluíram as séries temporais. Essa heterocedasticidade do modelo é indesejada, pois aumenta a chance de erros na previsão, de acordo com os resultados apresentados de MAPE, e outros tipos de erros estimados.

A notável boa performance do modelo de Box-Jenkins nas métricas estimadas

pelo sistema indica que existe a oportunidade de explorarmos com maiores detalhes estatísticos, em estudos futuros, o modelo SARIMA trabalhado, pois é possível que com um tratamento mais minucioso na base de dados o modelo também apresente o melhor resultado de performance em relação aos dados reais de vendas.

Considerando que nesse estudo é importante termos uma metodologia de implementação mais ágil pela empresa, então o modelo de Holt-Winters multiplicativo se mostra mais indicado para essa função, pois além de apresentar o melhor WMAPE, o tratamento dos dados é mais simples neste tipo de modelagem do que na metodologia de Box-Jenkins. Apesar dessa indicação, devido aos demais resultados apresentados pelo modelo, é aconselhável acompanhar a performance desse método ao longo do tempo, para garantir que o objetivo de melhor assertividade para gestão dos estoques seja alcançado.

8. REFERÊNCIAS BIBLIOGRÁFICAS

Association for Supply Chain Management, *APICS S&OP Performance Report - Advancing Sales and Operations Planning*, Chicago, 2017.

Beauty Hair. *Saiba quais as expectativas para o mercado de cosméticos em 2022*.

Beauty Hair. 2022. Disponível em: www.beautyhaircosmeticos.com/post/saiba-quais-as-expectativas-para-o-mercado-de-cosmeticos-em-2022. Acesso em: 15/10/2022.

BOX, George E. P. e JENKINS, Gwilym. *Time Series Analysis: Forecasting and Control*. Oakland, Holden-Day, 1976 (edição revisada).

Cosmetic Innovation. *Mercado de beleza cresce lento, mas continua em alta*.

Cosmetic Innovation, 2019. Disponível em: www.cosmeticinnovation.com.br/mercado-de-beleza-cresce-lento-mas-continua-em-alta/. Acesso em: 15/10/2022.

FAVA, Vera Lucia. *Metodologia de Box-Jenkins para Modelos Univariados. Manual de Econometria*. Vasconcelos, M.A.S. & Alves, D. Editora Atlas, São Paulo, 2000.

FIGUEIREDO, Adriano Marcos Rodrigues. *Séries Temporais com R: Análise do Consumo do Varejo em MS*. Campo Grande-MS, Brasil: RStudio/Rpubs, 2019. Disponível em http://rpubs.com/amrofi/arima_varejoms.

GOMES, Carlos Francisco. *Os modelos Arima e a abordagem de Box-Jenkins uma aplicação na previsão do IBOVESPA a curtíssimo prazo*. Revista de Administração de Empresas, Scielo, 2013.

HOLT, C. E. *Forecasting seasonals and trends by exponentially weighted averages* (O.N.R. Memorandum No. 52). Carnegie Institute of Technology, Pittsburgh USA. 1957.

HYNDMAN R.J., ATHANASOPOULOS G., *Forecasting: principles and practice*, 2nd edition, Melbourne, OTexts, 2018.

HYNDMAN R. J., KHANDAKAR, Y. *Automatic Time Series Forecasting: The forecast Package for R*. Journal of Statistical Software, 27(3), 1–22. <https://doi.org/10.18637/jss.v027.i03>. 2008.

KWIATKOWSKI D., PHILIPS P., SCHMIDT P. and SHIN Y. *Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?*. Journal of Econometrics, Elsevier, vol. 54. 1992.

LIMA, José Eduardo de Carvalho; CASTRO, Lucas Ferreira de; CARTAXO, Glauber Araújo Alencar. *Aplicação do Modelo SARIMA na Previsão de Demanda no Setor Calçadista*. Id on Line Rev.Mult. Psic., 2019, vol.13, n.46, p. 892-913.

MAKRIDAKIS, S.; WHEELWRIGHT, S.; HYNDMAN, R. *Forecasting: Methods and Applications*, 3rd ed.; JohnWiley & Sons: New York, NY, USA, 1998.

Plannera. *Como medir o seu planejamento de demanda*. Plannera, 2022. Disponível em: www.plannera.com/blog/como-medir-o-seu-planejamento-de-demanda/. Acesso em: 15/10/2022.

PELLEGRINI, Fernando R. *Metodologia para Implementação de Sistemas de Previsão de Demanda*. 2000. 146 f. Dissertação (Pós-Graduação em Engenharia de Produção) - Escola de Engenharia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

SAKAMOTO, Y., ISHIGURO, M., KITAGAWA G. (1986). *Akaike Information Criterion Statistics*. D. Reidel Publishing Company

WALLACE F. Thomas, *S&OP – Planejamento de Vendas e Operações*. 2 ed. IMAM.

WINTERS, P. R. (1960). *Forecasting sales by exponentially weighted moving averages*. Management Science, 6(3), 324–342. [DOI]

9. APÊNDICES

Apêndice 1. Vendas Históricas da Empresa

Ano	Mês	Maquiagem	Cuidados Corporais	Cuidados Faciais	Perfumaria	Higiene Pessoal	Cuidados Capilares
2015	1	247	9070	867	9342	17390	8987
2015	2	144	5870	213	3310	9489	10687
2015	3	183	6787	772	3223	11183	3419
2015	4	185	6683	520	3244	11505	4451
2015	5	934	10546	642	5191	14468	3340
2015	6	249	8026	630	3884	11200	4214
2015	7	376	9301	1084	9250	19593	11319
2015	8	170	8683	764	3620	14702	3565
2015	9	201	8848	437	3281	12020	4446
2015	10	264	11922	527	4205	16501	4391
2015	11	699	16407	776	6448	22395	8409
2015	12	507	56617	1560	14569	74739	8273
2016	1	460	21404	926	8909	24336	17055
2016	2	42	11494	421	3807	14528	4351
2016	3	16	12661	449	3677	15130	3876
2016	4	48	15708	520	4368	17305	4259
2016	5	48	21314	721	5900	23917	5861
2016	6	46	12873	734	3852	17567	6636
2016	7	20	13680	1313	5458	17642	9835
2016	8	4	13161	1595	4419	19738	5366
2016	9	4	16006	1178	4210	22381	4094
2016	10	2	16076	1327	4888	25247	4697
2016	11	0	23587	2054	7423	34541	5357
2016	12	0	83087	3707	16590	102027	7500
2017	1	0	26691	2374	8074	28940	6802
2017	2	0	15740	1053	4679	25374	3941
2017	3	0	20478	1281	6766	28741	4822
2017	4	0	23456	1270	6669	28746	4784
2017	5	0	37279	1442	9632	43290	4928
2017	6	0	24500	1431	5918	32690	4327
2017	7	0	33697	2461	12386	38176	7183
2017	8	0	26590	2223	8750	38143	5790
2017	9	0	31006	1151	11094	36723	5842
2017	10	0	32145	976	10892	39789	5497
2017	11	0	50476	1842	24112	64674	10350
2017	12	0	125706	4574	29559	162158	9504
2018	1	0	36618	1168	13755	37405	5657
2018	2	0	23207	642	9710	29402	3284
2018	3	0	35028	895	10309	37635	9344
2018	4	0	32238	751	9765	33527	11952
2018	5	0	48425	1239	17882	50968	9219
2018	6	0	30229	1411	15052	32737	7417
2018	7	2	31521	1969	11737	35385	8762
2018	8	857	35192	3938	18898	44257	13766
2018	9	1569	34958	1747	18798	44633	12574

Ano	Mês	Maquiagem	Cuidados Corporais	Cuidados Faciais	Perfumaria	Higiene Pessoal	Cuidados Capilares
2018	10	3828	39948	1917	13747	44218	12102
2018	11	1110	81604	3037	25582	75427	33359
2018	12	1072	147731	6844	30327	140476	51610
2019	1	424	36218	1345	10292	41125	14873
2019	2	317	32826	1177	8409	27484	9479
2019	3	319	30068	1516	16254	34721	15664
2019	4	391	37301	1150	10293	30579	15165
2019	5	2643	60371	1380	17185	49982	12787
2019	6	1367	36714	3113	13634	31709	10725
2019	7	1568	38923	2602	13758	30625	12574
2019	8	1006	42368	2649	10984	32574	11015
2019	9	616	36195	1588	11438	29792	9945
2019	10	2552	42693	2742	15044	36947	14802
2019	11	1352	52993	4924	18591	46446	25444
2019	12	1365	128385	5648	34327	114830	37468
2020	1	3018	37451	3000	15194	35875	18338
2020	2	2455	30534	970	13756	29091	9509
2020	3	1219	19530	802	7888	20192	8157
2020	4	395	7837	466	3656	9391	4132
2020	5	833	18134	784	7719	17511	7668
2020	6	844	14934	2904	7449	15329	7510
2020	7	1801	21207	4744	10278	25074	10468
2020	8	2279	20960	4533	12374	32257	12236
2020	9	1470	26281	4719	14171	33569	19955
2020	10	1071	33786	3982	15717	43564	10918
2020	11	1369	56398	4998	24417	60109	19102
2020	12	2425	185616	10239	57282	178151	21552
2021	1	877	31199	5760	16162	38851	16065
2021	2	845	25543	3389	12104	32795	9081
2021	3	597	17501	4161	10864	23438	16554
2021	4	795	25515	3056	15256	29123	14065
2021	5	1720	60900	6258	30018	57490	17656
2021	6	1788	45859	4038	19027	39258	20622
2021	7	1657	49943	2870	16245	38928	22583
2021	8	1433	36911	6486	16790	46874	13002
2021	9	1074	40853	7798	16828	45088	21594
2021	10	1006	49481	11784	20601	53671	18449
2021	11	843	74536	7647	28086	72250	24099
2021	12	1802	215986	7564	62421	242162	28497
2022	1	819	38844	2311	15415	38534	16152
2022	2	3617	33774	2824	14070	37001	11745
2022	3	5665	43912	7088	20735	55202	13743
2022	4	1672	44996	9522	23617	58108	11491
2022	5	8237	75678	7307	34446	78133	13748
2022	6	5158	41252	3884	25094	44220	11659

Fonte: Empresa fabricante de cosméticos (2022)