



UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO DE TECNOLOGIA E GEOCIÊNCIAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

JÚLIA FIGUEREDO DE ALENCAR

**SELEÇÃO DE MODELO DE PREVISÃO DE DEMANDA AGREGADA PARA SÉRIE
TEMPORAL NO SETOR INDUSTRIAL DE TINTAS E VERNIZES**

Recife

2020

JÚLIA FIGUEREDO DE ALENCAR

**SELEÇÃO DE MODELO DE PREVISÃO DE DEMANDA AGREGADA PARA SÉRIE
TEMPORAL NO SETOR INDUSTRIAL DE TINTAS E VERNIZES**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Universidade Federal de Pernambuco, como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção.

Orientador: Prof. DSc. Márcio das Chagas Moura.

Recife

2020

Catálogo na fonte:
Bibliotecária Sandra Maria Neri Santiago, CRB-4 / 1267

- A368s Alencar, Júlia Figueredo de.
Seleção de modelo de previsão de demanda agregada para série temporal no setor industrial de tintas e vernizes / Júlia Figueredo de Alencar. – 2020.
50 f.: il., fig., tabs.
- Orientador: Prof. MSc. Márcio das Chagas Moura.
TCC (Graduação) – Universidade Federal de Pernambuco. CTG. Departamento de Engenharia de Produção, Recife, 2020.
Inclui referências e apêndices.
1. Engenharia de produção. 2. Previsão de demanda. 3. Previsão de vendas. 4. Tintas e vernizes. 5. Séries temporais. 6. Previsão agregada. 7. MAE. I. Moura, Márcio das Chagas (Orientador). II. Título.

UFPE

658.5 CDD (22. ed.)

BCTG/2022-71

JÚLIA FIGUEREDO DE ALENCAR

**SELEÇÃO DE MODELO DE PREVISÃO DE DEMANDA AGREGADA PARA SÉRIE
TEMPORAL NO SETOR INDUSTRIAL DE TINTAS E VERNIZES**

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Produção da Universidade Federal de Pernambuco, Centro de Tecnologia e Geociências, como requisito parcial para a obtenção do grau de Bacharel em Engenharia de Produção.

Aprovado em: 09 / 12 / 2020.

BANCA EXAMINADORA

Prof. Dr. Márcio das Chagas Moura (Orientador)
Universidade Federal de Pernambuco

Prof. Dr. Isis Didier Lins (Examinadora Interno)
Universidade Federal de Pernambuco

Profa. Dra. Eduarda Asfora Frej (Examinadora Interna)
Universidade Federal de Pernambuco

“A todos esses que em mim atingiram zonas assustadoramente inesperadas, todos esses profetas do presente e que a mim me vaticinaram a mim mesmo a ponto de eu neste instante explodir em: eu“ (LISPECTOR, 1998, p. 9).

AGRADECIMENTOS

A entrega deste trabalho marca a conclusão da minha graduação, um período de muitas experiências e conquistas, que devo a muitas pessoas. Aqui, exprimo meu mais profundo agradecimento:

Agradeço aos meus pais, Ana Alice e Carlos, e meu irmão Matheus, que me deram todos os meios para construir a base educacional que me trouxe à UFPE, e todo o amor e apoio ao longo desse processo. Agradeço a meus tios e primos, que me serviram de exemplo na busca pelo aprendizado.

Obrigada ao DEP pela graduação completa, com excelentes professores que se preocuparam em compartilhar conhecimento. A dinamicidade do curso com as disciplinas eletivas me permitiu construir a grade que melhor atendeu a meus objetivos. Agradeço ao professor Márcio das Chagas por ter me orientado neste trabalho.

A meus amigos, agradeço pela presença e apoio, pelos estudos conjuntos e trabalhos em grupo, mas também pelas boas risadas e discussões que me fizeram entender que a universidade é muito mais do que um local para o ensino formal. Um agradecimento especial a Thais Campos, por me enviar as informações do BRAFITEC, abrindo as portas para meu intercâmbio.

Obrigada ao DAEP por ter me ensinado sobre liderança, trabalho em time e o poder da comunicação e da diversidade de opiniões, e por me fazer ver o impacto positivo que estudantes podem ter no ambiente acadêmico. Obrigada a Pedro Melo por ter me aconselhado e incentivado ao longo desse período.

Agradeço ao Clube de Consultoria UFPE por ter me apresentado a esse mundo que hoje torna minha carreira. Obrigada a Lucas Cainã pela mentoria e apoio nesses primeiros passos, e a todos os membros pelos aprendizados, estudos e *cases*.

Sobretudo, um agradecimento à UFPE por uma experiência genuinamente feliz, por me pôr em contato com tantas pessoas fantásticas e oportunidades inigualáveis, por um ensino público com direito a monitoria, iniciação científica, diretório acadêmico, intercâmbio acadêmico, clube de consultoria e a vida em campus.

Com todo o carinho,
Júlia Figueredo de Alencar

RESUMO

A previsão de demanda é um aspecto crucial para o bom planejamento de recursos e de vendas. O uso de computadores para fazer previsões tornou-se padrão para agilizar análises, contando inclusive com linguagens de programação específicas para análises estatísticas. Neste trabalho, é buscada uma forma computacional de melhorar a previsão de demanda para uma empresa do setor industrial de tintas e vernizes a fim de entender o comportamento das vendas de seus produtos para melhor embasar o pedido de compra de matérias primas. É, então, proposto um método de previsão de demanda agregada para as linhas de produtos da empresa em questão, verificando o melhor ajuste da previsão para cada uma, através da medida de erro MAE, dentre seis modelos diferentes: Amortecimento Exponencial Simples, Duplo e Triplo, Decomposição Clássica, Decomposição STL e ARIMA. Para esse fim, foi desenvolvido um algoritmo em R que testa os modelos e traz as medidas do MAE para comparação e seleção. São, então, apontados os melhores modelos para cada linha de produtos, trazendo os resultados da previsão e, por fim, discutindo os resultados. Identificou-se que o modelo de Amortecimento Exponencial Triplo obteve o melhor resultado na maioria dos casos analisados para o contexto dado.

Palavras-chave: previsão de demanda; previsão de vendas; tintas e vernizes; séries temporais; previsão agregada; MAE.

ABSTRACT

Demand forecasting is a fundamental factor for good resources and sales planning. The use of computers for predictions has become a standard to streamline analysis, including the use of specific programming languages for statistical analysis. In this article, we attempt to find a computational way to improve the demand forecasting for a company in the paint and varnish industry, which needed to better understand its products sales behavior to enable coherent purchase orders for raw material. A method is proposed for making an aggregated demand forecast for the company's product lines, verifying the best forecast adjustment for each line through the error measure MAE, amongst six available models: Classical Decomposition, ARIMA, STL Decomposition, Simple Exponential Smoothing, Holt's Linear Trend Model and Holt-Winter's Seasonal Method. For that end, we developed an algorithm in R, which tests the models and returns the MAE measures for comparison and selection. The best forecast model for each product line is chosen, with its forecast results and, as last, the results are discussed. The Triple Exponential Smoothing model presented a better result in the majority of the analyzed cases for the given context.

Key words: demand forecasting; sales forecasting; paints and varnishes; time series; aggregate forecast; MAE.

SUMÁRIO

1	INTRODUÇÃO	10
1.1	JUSTIFICATIVA E RELEVÂNCIA	11
1.2	OBJETIVOS	13
1.2.1	Objetivo geral.....	13
1.2.2	Objetivos específicos.....	13
1.3	METODOLOGIA.....	13
1.4	ORGANIZAÇÃO DO TRABALHO	15
2	FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA	16
2.1	FUNDAMENTAÇÃO TEÓRICA	16
2.1.1	Séries temporais.....	16
2.1.2	Previsão de séries temporais.....	16
2.1.2.1	A escolha dos modelos de previsão	17
2.1.2.2	Decomposição Clássica	17
2.1.2.3	Amortecimento Exponencial	18
2.1.2.3.1	<i>Amortecimento Exponencial Simples (AES).....</i>	<i>18</i>
2.1.2.3.2	<i>Amortecimento Exponencial Duplo (Método de Holt)</i>	<i>19</i>
2.1.2.3.3	<i>Amortecimento Exponencial Triplo (Método de Holt-Winters)</i>	<i>20</i>
2.1.2.4	Decomposição STL	20
2.1.2.5	ARIMA.....	21
2.1.3	Métricas de erro.....	21
2.1.3.1	Raíz quadrada do erro médio quadrático (RMSE)	22
2.1.3.2	Erro médio absoluto (MAE).....	22
1.5	REVISÃO DA LITERATURA	23
3	ABORDAGEM PARA CONDUÇÃO DA PESQUISA.....	27
4	SELEÇÃO DE SÉRIES	29
4.1	DESCRIÇÃO DAS SÉRIES ESCOLHIDAS	29
4.1.1	Látex	29
4.1.2	Massas.....	30
4.1.3	Esmalte e óleo.....	32
5	RESULTADOS	34
6	CONCLUSÃO.....	40
6.1	LIMITAÇÕES E TRABALHOS FUTUROS	40

REFERÊNCIAS	42
APÊNDICE A – ALGORITMO IMPLEMENTADO.....	44

1 INTRODUÇÃO

Durante a evolução da Engenharia de Produção foram desenvolvidas várias metodologias de análise de dados, previsões e gestão da produção, de projetos e da qualidade, abrangendo diversos aspectos de uma organização. Essas metodologias vêm sendo cada vez mais utilizadas por empresas em busca de eficiência e excelência. O objetivo claro do uso dessas técnicas é proporcionar um crescimento financeiro na companhia, muitas vezes através de melhorias no uso de seus recursos (GRIMSON & PYKE, 2007).

Há, entretanto, um frequente desencontro de informações entre os vários setores das empresas, impedindo que uma melhoria em determinada área se reflita em melhoria generalizada na operação. Grimson e Pyke (2007) citam o exemplo: uma maior restrição nas decisões de inventário pode ter impactos negativos na flexibilização do preço por parte da área de vendas. Isso serve de argumento para defender o planejamento integrado da produção e da demanda (ou operação e vendas), conhecido como *Sales and Operations Planning* (S&OP).

Um dos principais motivadores de um bom planejamento integrado da produção é evitar perdas. O conceito de perdas da produção é apresentado no Sistema Toyota de Produção (STP), uma das maiores referências em termos de eficiência e eficácia em processos produtivos. A eliminação de perdas é um de seus principais pilares (SHINGO, 1996), e estas consistem em atividades dispensáveis e custosas, classificadas pelo STP em sete categorias: superprodução, transporte, processamento, movimentação, inventário, defeitos e espera.

Moreira (2015) aponta que uma forma de prevenir perdas evitáveis é o uso de técnicas de previsão de demanda como guia para conduzir a produção. Quando essas técnicas são coerentes com o negócio, podem ter impactos relevantes na geração de valor do processo produtivo. Em situações nas quais a previsão de demanda de uma empresa encontra-se desalinhada da realidade, promove-se um aumento nas perdas por superprodução e por inventário, descritas a seguir:

- **Perda por superprodução:** consiste em produzir mais itens do que o mercado realmente vai consumir, causando gastos que não levarão a lucros, caso o produto não venha a ser vendido, ou causando um aumento no estoque até que seja de fato vendido em outro momento.
- **Perda por inventário:** ocorre quando há um acúmulo de estoque de matérias primas, materiais em processamento e produtos acabados, promovendo gastos com espaço físico.

Além dessas, há também perdas associadas à perda por demanda não atendida, quando a demanda supera a produção. Estas não são classificadas pelo STP, mas se relacionam à perda de vendas, que afeta a imagem da marca, a fidelidade do cliente final e o potencial financeiro desperdiçado.

Diante de diversos métodos existentes de previsão de demanda, muitas vezes organizações não possuem *know how* para implementar o modelo mais adequado a seus produtos e isso pode levar a estimativas pouco confiáveis. Diante disso, esta pesquisa intenciona a criação de um modelo de previsão agregada que compara diferentes métodos verificando a melhor adequação para a realidade da empresa e permitindo previsões mais confiáveis para uso.

O modelo proposto será aplicado sobre uma série de dados obtida de uma empresa do setor industrial, no ramo de fabricação de tintas e produtos relacionados, que será melhor contextualizada ao longo do trabalho, e os resultados dessa aplicação serão analisados e criticados.

Uma vez calculadas as previsões agregadas, sugere-se que sejam desagregadas proporcionalmente aos volumes históricos de venda de cada produto específico pertencente à linha de produtos para obter as previsões individuais.

A motivação na condução da pesquisa no tema vem da possibilidade da aplicação de conceitos-base da Engenharia de Produção na prática de empresas, melhorando suas operações. Entende-se que o uso de processos automatizados melhora a eficiência do processo de previsão, e esta pesquisa visa propor um método de avaliação de modelos que se adapte à realidade das empresas.

1.1 JUSTIFICATIVA E RELEVÂNCIA

A empresa associada à série de dados utilizada para este estudo pertence ao ramo fabril da indústria de tintas e vernizes, com atuação no Brasil. Segundo Souza, Gianezini e Watanabe (2018), o Brasil é um dos maiores produtores mundiais de tintas, mercado principalmente pelas tintas imobiliárias, relacionando-se diretamente com o mercado imobiliário da construção civil.

O setor industrial de tintas é caracterizado por sua produção em processo contínuo, no qual a base de insumos é a mesma para produtos da mesma linha, havendo diferenciação nas últimas etapas do processo produtivo e discretização apenas no envase. A produção é feita em

lotes para coordenar o uso das linhas de produção (maquinário) que são reutilizadas para diversos produtos.

Segundo entrevistas com os colaboradores da empresa, os fornecedores possuem um longo *lead time* para entrega de insumos à produção e é necessário, portanto, fazer pedidos de grande volume para suprir três meses de sua produção e ter um bom planejamento e boa gestão de estoques, definindo a política de estoques para o trimestre de acordo com a previsão de vendas do período.

Na realidade da empresa, a baixa acurácia na previsão de demanda acarreta severos problemas de produção, percebidos ao longo da cadeia e por diferentes setores. Foi identificada, então, a necessidade de se buscar um novo método de previsão de demanda para evitar a recorrência dessas situações.

Os custos associados aos erros produtivos, tais como produção de itens sem venda e compra de insumos desnecessários, levando a altos custos de estoque, além de um mau dimensionamento orçamentário, levam a empresa a valorizar a melhoria de seus métodos de previsão para estimar a demanda futura.

O método até então vigente para previsão de demanda foi apontado como principal causador dos seguintes problemas, de acordo com entrevistas nas respectivas áreas:

- PCP: falta de visão para planejamento a médio/longo prazo;
- Indústria: falta de matéria-prima e embalagens, levando a *stockouts* (esgotamentos de estoque);
- Produção: ociosidade na linha devido à falta de algum insumo ou embalagem durante a produção.

Ao observar uma série temporal, é possível que se busquem estimativas sobre o comportamento futuro da mesma, como em previsões de demanda. A previsão é utilizada como meio de melhor controlar, neste caso, a cadeia produtiva da empresa.

Partindo de estimativas dos valores de vendas para os meses subsequentes, pode-se fazer melhores negociações na aquisição de matéria-prima. Conhecendo-se o volume que será necessário para o período, tomar decisões quanto às políticas de estoque da fábrica e dos centros de distribuição possibilita o reabastecimento de maneira estratégica.

Visando aprimorar a previsão de demanda da empresa para que sua aquisição de insumos seja a mais adequada possível – considerando os dados disponíveis –, esta pesquisa busca desenvolver um método de seleção de modelo de previsão de demanda agregada a ser implementado na empresa em questão.

Entende-se que o método de seleção proposto pode ser aplicado em outras empresas do ramo de tintas e vernizes, bem como em outras indústrias que têm desafios semelhantes em seu planejamento. Os modelos de previsão utilizados são adequados especialmente em casos de séries curtas, por não necessitarem de extensas séries de treino, e com previsão a curto prazo.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Este trabalho tem como objetivo geral implementar um método automatizado de previsão de demanda agregada para séries temporais de múltiplas linhas de produtos de uma empresa do setor de tintas e vernizes.

1.2.2 Objetivos específicos

Os objetivos específicos deste trabalho são:

- Identificar as linhas de produtos mais relevantes através do tratamento da série de dados, agrupando as informações de acordo com os outputs desejados;
- Desenvolver um algoritmo que implemente modelos de previsão de séries temporais, com o uso da linguagem R;
- Fazer uma análise comparativa quanto à adequação dos modelos testados à série de dados disponível.

1.3 METODOLOGIA

Tratando-se de um estudo feito para aplicação em um projeto real, a pesquisa é de finalidade aplicada. A pesquisa aplicada é, segundo Gil (1999), caracterizada por um interesse na aplicação prática do conhecimento e nos resultados dessa aplicação num determinado contexto. O fluxograma do processo metodológico implementado nesta pesquisa é apresentado na Figura 1 e é detalhado nos próximos parágrafos.

Foi feito um contato inicial com as diversas áreas da empresa para entender seu contexto e a importância de se desenvolver este método. Uma vez entendido o problema, alinou-se com a empresa a proposta de solução e foi concedido o acesso aos dados históricos para aplicação na pesquisa e testes iniciais.

A revisão bibliográfica buscou entender o contexto atual das pesquisas acadêmicas, entender melhores práticas na aplicação e comparação de modelos de previsão e as possíveis lacunas na literatura a serem preenchidas com este trabalho.

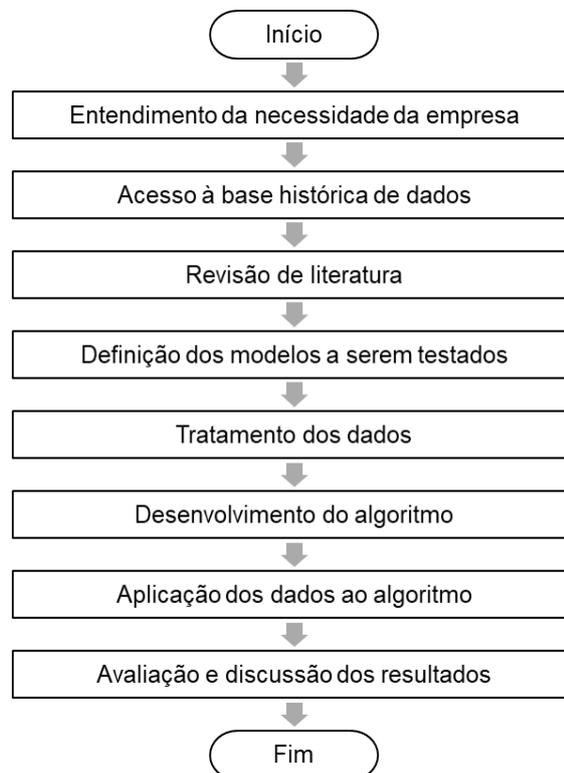
O estudo envolve a aplicação de seis diferentes modelos de previsão de demanda, verificando qual melhor se aplica a cada linha de produto escolhida, através do uso de um algoritmo desenvolvido em linguagem computacional R.

Os modelos escolhidos para verificar adequação foram a Decomposição Clássica, ARIMA, Decomposição STL, Amortecimento Exponencial Simples, Duplo e Triplo, escolhidos com base nas características da previsão.

O algoritmo foi desenvolvido em R, fazendo a leitura das séries de dados, aplicando os modelos e gerando um *output* de erros para cada modelo nas séries implementadas, permitindo comparação de seus desempenhos. Os dados tratados foram aplicados ao algoritmo e os resultados obtidos foram analisados e discutidos.

Dada a necessidade de previsão da empresa, foi necessário fazer o tratamento da base de dados de vendas históricas entre janeiro de 2016 e março de 2019, agrupando os volumes de vendas por mês. Os valores da série foram também normalizados, de forma a manter sigilo dos dados reais da empresa.

Figura 1 – Fluxograma do processo metodológico desta pesquisa



Fonte: O autor (2020)

1.4 ORGANIZAÇÃO DO TRABALHO

Tendo em vista o atingimento dos objetivos, geral e específicos, o presente trabalho divide-se em cinco capítulos, sendo o presente capítulo o primeiro, no qual é feita uma introdução ao tema e contextualização.

O segundo capítulo traz a fundamentação teórica dos conceitos que serão abordados ao longo do trabalho, tais como séries temporais, os métodos de previsão de demanda que serão explorados (decomposição clássica, decomposição STL, amortecimento exponencial e ARIMA). No mesmo capítulo, é feita uma breve revisão da literatura a respeito do tema.

No terceiro capítulo é descrita a abordagem escolhida para a condução da pesquisa e justificativa de aspectos importantes para o desenvolvimento do algoritmo – explicando o método escolhido – dentro do contexto da empresa.

O quarto capítulo descreve as decisões associadas à seleção de quais linhas de produtos foram analisadas para que delas fossem extraídos os resultados mais representativos da previsão de demanda.

No quinto capítulo são apresentadas as tabelas e gráficos resultantes da implementação do método, permitindo a discussão dos resultados obtidos e a seleção do melhor modelo para cada linha de produtos escolhida.

Por fim, o sexto capítulo traz as conclusões, as limitações do trabalho e possíveis melhorias para desenvolvimentos futuros.

2 FUNDAMENTAÇÃO TEÓRICA E REVISÃO DA LITERATURA

2.1 FUNDAMENTAÇÃO TEÓRICA

2.1.1 Séries temporais

Segundo Chatfield (1996), pode ser classificado como série temporal um conjunto de observações feitas ao longo do tempo, de maneira sequenciada. Elas podem ser classificadas como discretas quando as observações são coletadas em momentos específicos do tempo, geralmente igualmente espaçados, ou quando os valores das observações são agregados em intervalos igualmente espaçados (por exemplo, agrupar vendas por dia, semana ou mês, mesmo que as vendas sejam feitas por diversos vendedores ao longo do dia).

Séries temporais possuem o aspecto de que as observações não são independentes e a ordem delas é relevante para a análise, de forma que o futuro da série possui uma distribuição probabilística vinculada ao conhecimento dos valores passados.

Para melhor compreensão dos vários padrões que podem ser observados em uma série temporal, é comum que se faça uma decomposição da série em componentes, de forma que cada componente represente um padrão de comportamento da série, sendo eles tendência, sazonalidade, ciclo e o componente irregular. A seguir, tendência e sazonalidade são brevemente explicadas.

Doane e Seward (2014) explicam que há tendência quando se identifica uma mudança sistemática na média da série, como crescimento ou decaimento, por exemplo. É dito que há sazonalidade quando há uma variação repetitiva com periodicidade anual, podendo ter recorrências trimestrais, semestrais e afins.

2.1.2 Previsão de séries temporais

Previsão pode ser conceituada, segundo Montgomery, Jehnnings & Kulahci (2015), como uma estimativa de que um ou mais eventos aconteçam no futuro. O uso de técnicas de previsão é bastante difundido, compreendendo diversas aplicações como previsão de fenômenos meteorológicos, de falha de máquinas, de volume de vendas, entre outros. O uso de séries temporais é comum aos modelos de previsão de demanda, que buscam estimar valores relativos à demanda futura baseada em dados históricos.

2.1.2.1 A escolha dos modelos de previsão

Segundo Corrêa & Corrêa (2012), previsões de até três meses são consideradas de curto prazo. Para esse tipo de previsão é aceita a hipótese de que as tendências e ciclicidades do passado devem permanecer as mesmas, podendo-se usar técnicas de projeção observadas nos modelos intrínsecos ou de séries temporais simples.

Os modelos intrínsecos são assim chamados devido à correlação que fazem entre as vendas históricas e o tempo, projetando-as no futuro a partir da decomposição em componentes a serem modelados matematicamente; geralmente uma curva de tendência e fatores de sazonalidade. Os modelos classificados como intrínsecos são os de média móvel, amortecimento exponencial, projeção de tendências e decomposição (CORRÊA & CORRÊA, 2012).

Dentre os modelos intrínsecos, foram escolhidos os modelos de previsão apresentados na Tabela 1 para o teste de ajuste nesta pesquisa. Em seguida, os modelos são explicados.

Tabela 1 – Modelos escolhidos para a previsão de demanda

Tipo de modelo	Modelo escolhido
Média móvel	ARIMA
Amortecimento exponencial	Amortecimento Exponencial Simples; Amortecimento Exponencial Duplo (Holt); e Amortecimento Exponencial Triplo (Holt-Winters)
Decomposição	Decomposição Clássica; e Decomposição STL

Fonte: Adaptado de Hyndman & Athanasopoulos (2018)

2.1.2.2 Decomposição Clássica

A decomposição clássica serviu como base para outras formas de decomposição mais sofisticadas. É conhecida como *ETS*, uma sigla em inglês que representa erro, tendência e sazonalidade (*error, trend, seasonal*) devido aos componentes considerados em seu cálculo. Ela pode ser aditiva ou multiplicativa, fazendo a decomposição da série em seus componentes sazonal e de tendência.

Seus componentes são calculados através de um processo de otimização que busca os melhores valores desses elementos para a fórmula. A otimização dos componentes e a escolha

entre o modelo aditivo e o multiplicativo já são consideradas na função implementada no algoritmo em R.

Considerando:

y_t – Observação da série no instante t

S_t – Componente sazonal

T_t – Efeito de tendência

ε_t – Componente de erro aleatório

O modelo aditivo é tido pela fórmula geral:

$$y_t = S_t + T_t + \varepsilon_t \quad (2.1)$$

Já o modelo multiplicativo é tido por:

$$y_t = S_t T_t \varepsilon_t \quad (2.2)$$

2.1.2.3 Amortecimento Exponencial

O amortecimento exponencial utiliza-se de médias ponderadas de observações históricas para fazer suas previsões, reduzindo o peso atribuído aos valores exponencialmente à medida que eles se distanciam do presente, gradativamente fazendo-os perder a relevância sobre os valores mais recentes (HOLT, 1957). Para isso, é utilizado o parâmetro de amortecimento α , sendo $0 \leq \alpha \leq 1$.

O valor de α deve ser tal que atenuar adequadamente os efeitos de observações mais antigas. Se for muito próximo do 0, pode sujeitar a previsão a uma alta variabilidade aleatória; se for muito próximo do 1, atribui uma alta relevância mesmo aos valores mais antigos, que podem já não ter tanta influência sobre o comportamento da curva. Assim, a forma mais confiável de obter essa constante é através da estimativa baseada em dados históricos (HYNDMAN & ATHANASOPOULOS, 2018).

2.1.2.3.1 Amortecimento Exponencial Simples (AES)

Este modelo de previsão é utilizado quando não se identifica uma presença clara de componentes de tendência ou sazonalidade, sendo considerado adaptativo e de baixo custo computacional. Dessa forma, seus termos são calculados considerando apenas o nível da curva, tido pelo valor da observação no período de tempo anterior e pela constante de

amortecimento α , seguindo o sistema de equações (2.3) e (2.4), como explicam Hyndman e Athanasopoulos (2018).

$$\text{Equação de previsão: } \hat{y}_{t+h|t} = l_t \quad (2.3)$$

$$\text{Equação de nível: } l_t = l_{t-1} + \alpha(y_t - l_{t-1}) = \alpha y_t + (1 - \alpha)l_{t-1} \quad (2.4)$$

$\hat{y}_{t+h|t}$ – Previsão do valor para o instante $t + h$ para $h = 1, 2, \dots$

l_t – Nível, ou valor amortecido da série no instante t

l_{t-1} – Nível da série no instante $t - 1$

Onde $(y_t - l_{t-1})$ é o erro entre a previsão e o valor real no instante t .

2.1.2.3.2 Amortecimento Exponencial Duplo (Método de Holt)

Na intenção de permitir que o amortecimento exponencial se aplicasse também à previsão de séries sob efeito de tendência, Holt (1957) adaptou a fórmula do AES. Na adaptação de Holt, a previsão passa a ser feita considerando tanto o componente de nível quanto o de tendência, de acordo com o sistema de equações:

$$\text{Equação de previsão: } \hat{y}_{t+h|t} = l_t + hb_t \quad (2.5)$$

$$\text{Equação de nível: } l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.6)$$

$$\text{Equação de tendência: } b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (2.7)$$

l_t – Estimativa do nível da série no instante t

b_t – Estimativa da tendência da série no instante t

β – Constante de amortecimento da tendência $0 \leq \beta \leq 1$

A equação de nível apresenta l_t como uma média ponderada da observação no instante t e da previsão de valor para o instante anterior. De forma análoga, a equação de tendência tem b_t como uma média ponderada das estimativas de tendência para o instante t e para o instante anterior ($t - 1$).

2.1.2.3.3 Amortecimento Exponencial Triplo (Método de Holt-Winters)

Ainda em sua publicação, Holt (1957) apresenta uma forma de implementação do amortecimento exponencial que se aplica a séries sob efeito não só de tendência, mas também de sazonalidade. O atualmente conhecido como o Método de Holt-Winters, funciona de acordo com o sistema de equações:

$$\text{Equação de previsão:} \quad \hat{y}_{t+h|t} = l_t + hb_t + s_{t+h-m(k+1)} \quad (2.8)$$

$$\text{Equação de nível:} \quad l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (2.9)$$

$$\text{Equação de tendência:} \quad b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (2.10)$$

$$\text{Equação de sazonalidade:} \quad s_t = \gamma(b_{t-1} - l_{t-1}) + (1 - \gamma)s_{t-m} \quad (2.11)$$

m – Número de intervalos de repetição da sazonalidade no período

s_t – Estimativa de sazonalidade da série no instante t

γ – Constante de amortecimento da sazonalidade

k – Parte inteira de $(h - 1)/m$, para garantir que o índice de sazonalidade se refira ao período mais recente da amostra

É explicado por Hyndman e Athanasopoulos (2018) que a alteração na equação de nível para esse formato de amortecimento exponencial apresenta uma média ponderada entre a observação com o ajuste sazonal e a previsão sem sazonalidade. A equação de sazonalidade apresenta uma média ponderada entre o índice de sazonalidade corrente e o índice de sazonalidade para o mesmo intervalo no período anterior (por exemplo, os índices de sazonalidade de janeiro de 2019 e janeiro de 2020).

2.1.2.4 Decomposição STL

A decomposição STL, abreviação do inglês *Seasonal and Trend Decomposition Using Loess (Locally Estimated Scatterplot Smoothing)*, ou Decomposição Sazonal e de Tendência Usando Loess, em tradução livre, usa Loess para estimar relações não-lineares. Consiste em um processo de filtragem para efetuar a decomposição da série em componentes de tendência e sazonalidade.

O método, quando desenvolvido por Cleveland *et al.* (1990), tinha como objetivo ser de uso simples, direto e com fácil implementação computacional, de forma a permitir a

decomposição de séries com dados faltantes e permitindo que se determine o número de observações por ciclo sazonal. O uso de Loess na decomposição é o fator que permite que se trate a série com dados faltantes.

2.1.2.5 ARIMA

O acrônimo ARIMA vem do inglês *Autoregressive Integrated Moving Average* (pode ser traduzido como “média móvel integrada autorregressiva”), e seu conceito integra o Modelo Autorregressivo ao Modelo de Média Móvel, levando em conta também o grau de diferenciação (explicado abaixo) da série, pois seu uso requer que a série seja estacionária (MONTGOMERY, JEHNINGS & KULAHCI, 2015).

O modelo ARIMA (p, d, q) precisa ter seus parâmetros estimados definidos para cada série à qual será aplicado:

p – Ordem da parcela autorregressiva

d – Grau de diferenciação da série

q – Ordem da parcela de média móvel

Devido a essa composição, o modelo ARIMA apresenta a flexibilidade que permite sua aplicabilidade a uma grande variedade de tipos de séries.

Segundo Hyndman e Athanasopoulos (2018), a diferenciação é um procedimento de transformação feito em séries temporais para obter um comportamento estacionário, que é pré-requisito para o uso de alguns modelos de previsão. Se trata de utilizar as diferenças de valor entre os pontos de observação, e utilizando essas diferenças como a série. A diferenciação pode ocorrer tanto para pontos em sequência quanto para pontos separados por uma temporada, no caso de séries com sazonalidade. Esse procedimento é feito automaticamente na função implementada na linguagem R.

2.1.3 Métricas de erro

Em uma previsão, a diferença entre o valor previsto e o valor real é chamada de erro. Esse erro é medido para o período de teste do modelo (HYNDMAN & ATHANASOPOULOS, 2018). Existem diversos métodos de calcular esse erro, alguns que o representam em números absolutos e outros em percentual. Dentre os mais utilizados, estão o

MAE (*Mean Absolute Error* – Erro médio absoluto) e o RMSE (*Root Mean Squared Error* – Raíz quadrada do erro médio quadrático).

Hyndman (2019) frisa que o ranqueamento da performance dos modelos varia com a medida de erro utilizada. Por isso, é necessário entender as métricas de erro para selecionar as mais adequadas para o negócio. A seguir, são explicados os erros RMSE e MAE.

2.1.3.1 Raíz quadrada do erro médio quadrático (RMSE)

O RMSE é uma forma de impedir que os erros positivos e negativos se cancelem, levando a uma medida ilusória de baixo erro médio. O RMSE eleva o erro ao quadrado, e depois extrai a raíz quadrada, resultando no módulo do erro, que é o valor utilizado para o cálculo da média.

O valor do RMSE é um valor absoluto, medido de acordo com o valor dos pontos de dados da série, portanto deve ser considerado para comparações de acurácia para a mesma série, mas não para comparação entre séries distintas, pois não é um valor percentual. A equação 2.12 representa o cálculo do RMSE.

$$\text{Equação de RMSE: } \sqrt{\frac{1}{h} \sum_{t=1}^h (y_t - \hat{y}_t)^2} \quad (2.12)$$

\hat{y}_t – Previsão do valor para o instante t

y_t – Valor real no instante t

h – Número do período previsto para $h = 1, 2, \dots$

2.1.3.2 Erro médio absoluto (MAE)

O MAE mede a magnitude média dos erros em uma previsão, quando comparada à série de teste, desconsiderando se valor previsto está acima ou abaixo do valor de teste. A equação 2.13 descreve o cálculo do MAE.

$$\text{Equação de MAE: } \frac{1}{h} \sum_{t=1}^h |y_t - \hat{y}_t| \quad (2.13)$$

\hat{y}_t – Previsão do valor para o instante t

y_t – Valor real no instante t

h – Número do período previsto para $h = 1, 2, \dots$

O MAE é considerado uma medida mais simples de erro e seus valores podem ser facilmente compreendidos por quem os analisa. Considerando a intenção de que o algoritmo

proposto seja implementado e utilizado por uma empresa e prezando pela simplicidade de compreensão dos responsáveis pela operação da ferramenta, o MAE foi escolhido como métrica de erro para comparação dos modelos neste trabalho.

1.5 REVISÃO DA LITERATURA

A previsão de demanda é um tema amplamente estudado, devido a sua vasta aplicabilidade. No contexto industrial, a previsão de demanda é um dos principais *drivers* de ordens de compra de matérias-primas e embalagens, sobretudo quando o *lead time* entre solicitação e recebimento é elevado, cenário no qual o estoque precisa ser adequado para evitar o *stock-out* bem como o estoque excessivo devido a seus impactos financeiros.

A revisão bibliográfica para este trabalho foi feita sobre artigos das bases Web of Science e Scopus, além de livros didáticos em estatística e engenharia de produção. As principais palavras-chave utilizadas nas pesquisas foram: *demand forecasting, exponential smoothing, comparison, ARIMA, aggregate forecasting, paints and varnishes*, além de outras relacionadas ao tema da pesquisa.

Nesse contexto, a automatização da previsão é uma forma de simplificar esse processo, adequando-se à realidade de empresas. Hyndman *et al.* (2002) apontam a crescente necessidade de empresas pela automação de suas previsões, para ganhar em agilidade e nível de serviço. Esse processo de automação torna-se mais factível quando aplicado sobre séries agregadas, pois demandam menor custo computacional.

No estudo, Hyndman *et al.* (2002) buscam estruturar um framework para fazer a previsão com Amortecimento Exponencial, utilizando-se de automação para reduzir a necessidade de intervenção humana no cálculo da previsão, visto que a tarefa é repetitiva e sujeita a erros. Na pesquisa, são comparados diferentes métodos para a estimativa dos parâmetros de previsão no algoritmo, onde são considerados as medidas de erro AMSE, MSE, MLE, MAPE e σ^2 , julgando o AMSE e o MSE como os métodos com melhor performance.

Soto-Ferrari *et al.* (2019) conduziram um estudo envolvendo métodos simples de previsão, tais quais os usados no presente estudo, no qual verificam se a previsão de séries temporais traz resultados mais adequados em uma estratégia *top-down* (na qual a previsão é feita de maneira agregada para o conjunto das séries) ou em uma *bottom-up* (onde é feita uma previsão para cada série e depois as previsões são agrupadas para verificar o ajuste).

O estudo apresenta que, para o uso de Amortecimento Exponencial, a estratégia *top-down* traz maior acurácia do que a *bottom-up*, e o contrário se verifica para o uso de ARIMA. É apontado que o uso da previsão agregada proporciona agilidade computacional na execução do algoritmo, e que a variabilidade total é reduzida, quando comparada à técnica *bottom-up*.

Assim como Hyndman *et al.* (2002), e embasada no estudo de Soto-Ferrari *et al.* (2019), esta pesquisa utilizará a previsão agregada. Essa abordagem também busca evitar possíveis erros de previsão devido à granularidade de alguns produtos específicos, provocados por ausência de dados para alguns meses, a alta variabilidade nos valores e a grande quantidade de séries a serem analisadas.

Como mencionado previamente neste trabalho, o mercado imobiliário tem grandes influências sobre a indústria de tintas e vernizes. Entendendo a importância desse mercado para diversos setores da economia, Soy Temür, Akgün & Temür (2019) conduziram um estudo sobre a previsão de demanda do mercado imobiliário da Turquia, após identificar a escassez desse tipo de pesquisa.

Na pesquisa, são comparados os desempenhos de um modelo de previsão linear (ARIMA), uma arquitetura de redes neurais recorrente (LSTM – *Long Short-Term Memory*) e um modelo híbrido que combina ambas as abordagens, a partir de uma série temporal de 124 pontos correspondentes a dez anos de dados mensais do mercado imobiliário nacional turco.

Conclui-se que o modelo híbrido traz os resultados com menor erro percentual médio, seguido pelo ARIMA e, por fim, o LSTM. Entende-se que o modelo híbrido complementa as falhas de cada modelo isolado, e os pesquisadores frisam que o LSTM é implementado para *deep learning* e se beneficia de longas séries de dados históricos para aprendizado, como é o caso para a maioria dos modelos sofisticados de inteligência artificial.

Considerando a baixa disponibilidade de dados, bem como o curto horizonte de previsão, decidiu-se seguir com o uso de modelos de previsão linear para a presente pesquisa.

O uso de métricas de erro para a comparação entre métodos de previsão já é difundido na literatura. Hyndman (2019) faz uma revisão das competições de previsão existentes, frisando a importância que elas tiveram para a comunidade acadêmica ao identificar, para diferentes tipos de séries, a acurácia dos métodos existentes, bem como impulsionar o desenvolvimento de novos métodos de previsão que passaram a ser incorporados nas competições e comparados aos demais métodos já consolidados.

Dentre as competições existentes, uma das mais antigas e conhecidas é a série de *M-Competitions*, que já conta com quatro edições completas, e a quinta foi lançada em 2020. As *M-Competitions* são organizadas por times liderados pelo pesquisador Makridakis, e vêm

evoluindo ao longo dos anos, passando a incluir métodos de *machine learning* a partir da quarta edição (HYNDMAN, 2019).

Algumas das conclusões decorrentes das *M-Competitions* foram consideradas diretamente relevantes para este trabalho e estão listadas a seguir, de acordo com Hyndman (2019) e Makridakis & Hibon (2000):

- Métodos estatisticamente sofisticados ou complexos não necessariamente produzem previsões mais acuradas do que métodos mais simples;
- O ranqueamento da performance dos modelos vai variar com a medida de erro utilizada;
- A performance dos modelos depende do tamanho do horizonte de previsão.

Além das *M-Competitions*, Hyndman (2019) também discorre sobre outras competições, apresentadas na Tabela 2.

Tabela 2 – Outras competições de previsão e suas principais características

Competição	Características principais
Santa Fe	Apresentou seis séries temporais, aproximadamente dez vezes mais longas do que as apresentadas nas <i>M-Competitions</i> . A pequena amostra de séries não permitiu conclusões gerais.
KDD cup	Competição anual da comunidade de <i>data mining</i> que ocasionalmente envolve previsão de séries temporais, como foi o caso na edição de 2018, sobre níveis de poluição do ar em Pequim e Londres.
Neural network	Desenvolvida a partir da <i>M3-Competition</i> com o objetivo de encorajar as pesquisas com redes neurais. Concluiu que redes neurais não são apropriadas para prever séries temporais de uma só variável, devido à natureza curta das séries, com pontos insuficientes para um bom ajuste.
Kaggle time series	O Kaggle foi a primeira plataforma online dedicada a competições de <i>data mining</i> , e passou a ser utilizada por pesquisadores para propor competições em temas específicos. A plataforma dispõe de um ranking e permite várias submissões, o que estimula a competitividade.
Global energy forecasting	Organizadas em parceria com o <i>International Journal of Forecasting</i> , já conta com três edições focando em aspectos específicos da

	previsão de energia, tais como volume, preço, vento (energia eólica) e sol (energia solar). Nesta competição, é necessário fornecer o código com implementação dos modelos e submeter um artigo ao periódico descrevendo a abordagem.
--	---

Fonte: Adaptado de Hyndman (2019)

Reconhecendo a importância das competições de previsão para a evolução de modelos, o presente estudo focou não em participar de alguma competição, mas em usar as práticas difundidas de comparação de desempenho para diferentes modelos e séries dentro do contexto específico da empresa detentora dos dados, implementando-os de forma automatizada para fácil uso na prática empresarial.

3 ABORDAGEM PARA CONDUÇÃO DA PESQUISA

Neste capítulo, é descrita a abordagem utilizada para a condução da pesquisa bem como a justificativa de aspectos importantes para o desenvolvimento do algoritmo, detalhando as etapas de tratamento dos dados, desenvolvimento do algoritmo, aplicação dos dados ao algoritmo, apresentadas na Figura 1 da metodologia.

A empresa dispõe de uma base histórica de vendas do período de janeiro de 2016 a março de 2019, representando aproximadamente três anos de dados. Considerando uma periodicidade mensal, isso representa uma série com 39 pontos de observação.

As séries foram divididas em conjunto de treinamento e conjunto de teste da seguinte maneira: 36 pontos de observação para treinamento e os últimos três pontos para teste, considerando que a previsão desejada pela empresa será para os três meses seguintes.

Dado que a intenção da previsão de demanda é estimar os volumes de compra de matéria-prima e a política de estoques para o trimestre seguinte (mês a mês), a unidade utilizada na série de dados é de litros vendidos de produto. A Tabela 3.1 resume algumas características das séries. Todos os gráficos e tabelas apresentados neste trabalho estão com suas unidades normalizadas, de forma a preservar a confidencialidade dos dados.

Os produtos da empresa são agrupados em linhas comerciais, de modo que cada agrupamento possui características semelhantes, possuindo os mesmos insumos como ingredientes principais em cada fórmula. Isso permite que a previsão seja feita de forma agregada, gerando assim os volumes estimados de vendas que embasam as ordens de compra para os meses seguintes.

A empresa possui oito linhas comerciais, como listado na Tabela 3, cada uma representada por uma série de dados com 39 pontos de observação.

Tabela 3 – Lista de linhas comerciais

	Linha de produto		Linha de produto
1	Esmalte e Óleo	5	Solvente e Thinner
2	Látex	6	Texturas
3	Massas	7	Vernizes
4	Seladores	8	Outros

Fonte: O autor (2020)

O algoritmo foi desenvolvido em linguagem computacional R e está disponível no Apêndice A deste trabalho. A escolha da linguagem deve-se a suas propriedades estatísticas e bibliotecas adequadas para o trabalho com séries temporais, tais como a *forecast*, que permite a implementação de funções-chave, listadas na Tabela 4, para a execução dos modelos de maneira rápida.

Tabela 4 – Principais funções utilizadas e sua funcionalidade

Função em R	Funcionalidade
<i>ses</i> ()	Retorna a previsão para amortecimento exponencial simples
<i>holt</i> ()	Retorna a previsão para amortecimento exponencial duplo
<i>hw</i> ()	Retorna a previsão para amortecimento exponencial triplo
<i>ets</i> ()	Fornecer os parâmetros de amortecimento para o uso da função <i>forecast</i> para Decomposição Clássica
<i>stlm</i> ()	Ajusta a base de treino para implementação da função <i>forecast</i> para Decomposição STL
<i>auto.arima</i> ()	Fornecer os parâmetros para o uso da função <i>forecast</i> para ARIMA
<i>forecast</i> ()	Função genérica para previsões com séries temporais a partir do método indicado – <i>ets</i> , <i>stlm</i> , <i>arima</i> ou outros
<i>accuracy</i> ()	Retorna um resumo das medidas de acurácia da previsão em comparação com a base real

Fonte: Adaptado de Hyndman & Athanasopoulos (2018)

O algoritmo faz a leitura e importação da base de dados em Excel, que contém os pontos de dados históricos de todas as linhas de produtos. Em *loop*, passa por cada uma das séries temporais, dividindo-as em séries de treino e de teste e em seguida aplica cada um dos 6 modelos de previsão, gerando o relatório de acurácia em formato de tabela.

O *output* do algoritmo são as previsões para os três meses de teste para cada modelo, acompanhadas de suas tabelas de acurácia, que consistem nas medidas de MAE associadas aos modelos aplicados.

Em seguida, os métodos são ranqueados de acordo com sua performance. Esta performance é medida pelo erro, numa razão inversamente proporcional: quanto menor o erro, melhor foi a performance do respectivo modelo. Dessa forma, será escolhido então o modelo com melhor ajuste, indicado como o melhor para realizar a previsão dos próximos três meses.

4 SELEÇÃO DE SÉRIES

As séries analisadas representam as diferentes linhas de produtos segundo a classificação da empresa estudada. Estas encontram-se todas no contexto da indústria de tintas e solventes no período de 2016 a 2019.

Para análise e discussão dos resultados da previsão, foram selecionadas 3 das séries de dados, referentes a linhas de produtos específicas. As linhas de produtos selecionadas foram Látex, Massas e Esmalte e Óleo, que juntas representam aproximadamente 86% do volume total anual vendido pela empresa, vide Tabela 5, sendo, assim, as linhas cuja melhoria na previsão de demanda deve trazer maior impacto para a empresa. Na tabela, as linhas de produtos selecionadas estão sublinhadas para facilitar a identificação.

Tabela 5 – Representatividade de cada linha de produto sobre o volume anual vendido

Linha de produto	2016	2017	2018
<u>Látex</u>	<u>50%</u>	<u>50%</u>	<u>52%</u>
<u>Massas</u>	<u>25%</u>	<u>24%</u>	<u>23%</u>
<u>Esmalte e Óleo</u>	<u>11%</u>	<u>13%</u>	<u>12%</u>
Seladores	5%	4%	4%
Outros	3%	4%	3%
Texturas	3%	2%	2%
Vernizes	2%	2%	2%
Solvente e Thinner	2%	1%	1%

Fonte: O autor (2020)

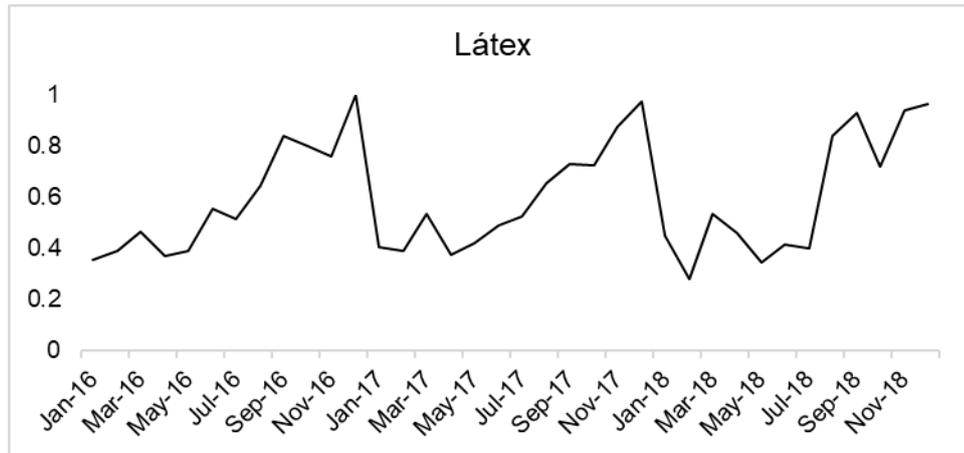
4.1 DESCRIÇÃO DAS SÉRIES ESCOLHIDAS

Nesta seção é descrito o comportamento das séries temporais das três linhas de produtos selecionadas para análise, quanto a sazonalidade e tendência observadas.

4.1.1 Látex

A linha Látex é composta de tintas imobiliárias, representando 50% do volume total vendido. O comportamento das vendas ao longo dos meses é descrito pelo gráfico da Figura 2. Ao longo dos anos, não se observa tendência expressiva, tendo apresentado um aumento do volume anual de apenas 1% no período.

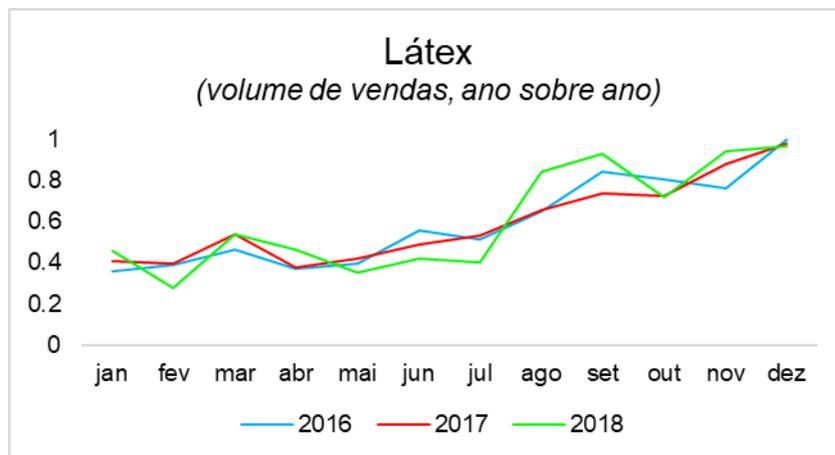
Figura 2 – Representação gráfica de evolução do volume de vendas da linha de produto látex



Fonte: O autor (2020)

Na Figura 3, as séries anuais são sobrepostas e pode-se observar aspectos de sazonalidade, como a baixa venda nos meses iniciais e um aumento gradativo quase contínuo, com um leve aumento em março, um pico local em setembro e o pico anual em dezembro.

Figura 3 – Representação gráfica da sobreposição entre as séries anuais da linha látex



Fonte: O autor (2020)

4.1.2 Massas

A segunda linha de maior expressividade no volume total de vendas, Massas, representa aproximadamente 23% dos litros vendidos e vem apresentando uma leve queda no volume total anual ao longo dos últimos anos. Entre 2016 e 2019, a linha de massas sofreu um decréscimo de 9% no volume anual vendido (observar Tabela 6). Esta linha é também associada ao mercado imobiliário, não sendo composta por tintas, mas por massas utilizadas no acabamento de paredes e superfícies.

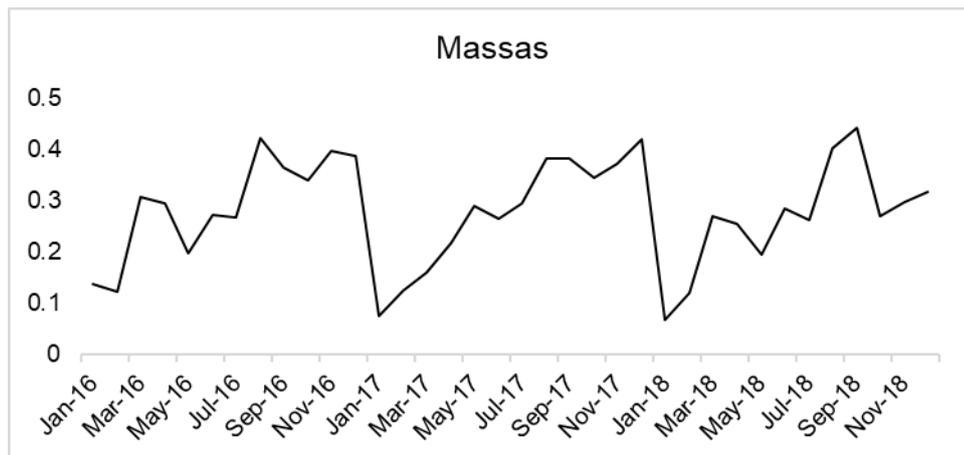
Tabela 6 – Volume de vendas anual da linha massas

Ano	Volume vendido
2016	3,5
2017	3,3
2018	3,2

Fonte: O autor (2020)

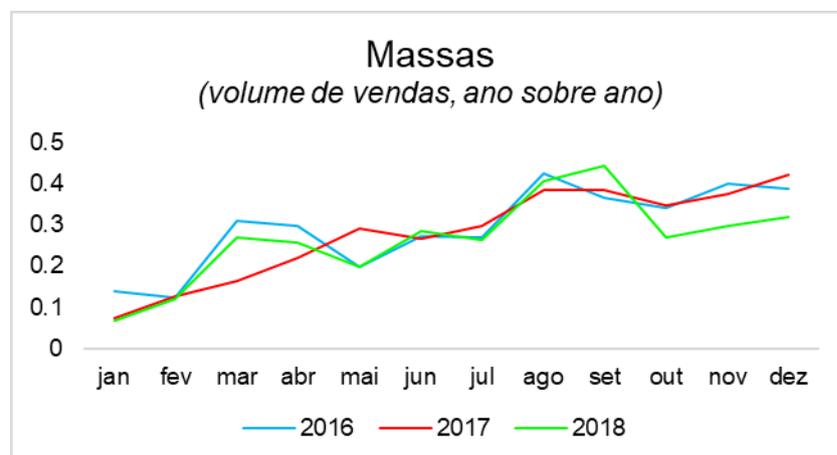
O comportamento histórico dessa linha de produtos pode ser observado na Figura 4. Na sobreposição das séries, apresentada na Figura 5, a linha dá indícios de uma sazonalidade marcada pela queda de vendas em janeiro que aumenta ao longo dos meses com oscilações, com o ano de 2017 (em vermelho) destoando dos demais anos por apresentar um comportamento mais contínuo, sem quedas ou picos mensais expressivos.

Figura 4 – Representação gráfica de evolução do volume de vendas da linha de produto massas



Fonte: O autor (2020)

Figura 5 – Representação gráfica da sobreposição entre as séries anuais da linha massas



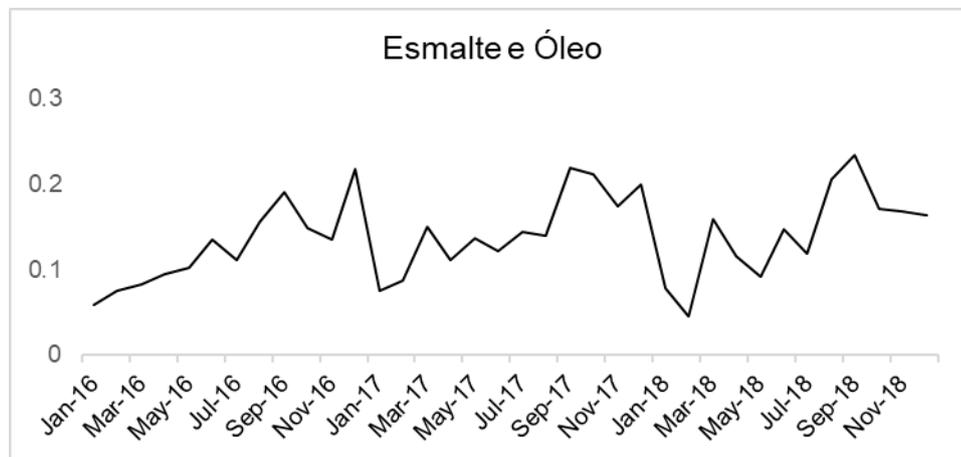
Fonte: O autor (2020)

4.1.3 Esmalte e Óleo

A linha Esmalte e Óleo, assim como a linha Látex, é composta por tintas imobiliárias. Entretanto, a diferença no volume vendido pode ser explicada devido ao preço mais alto cobrado pelo litro das tintas de Esmalte e Óleo, que chega a ser aproximadamente o dobro do cobrado nos produtos da linha Látex, em média.

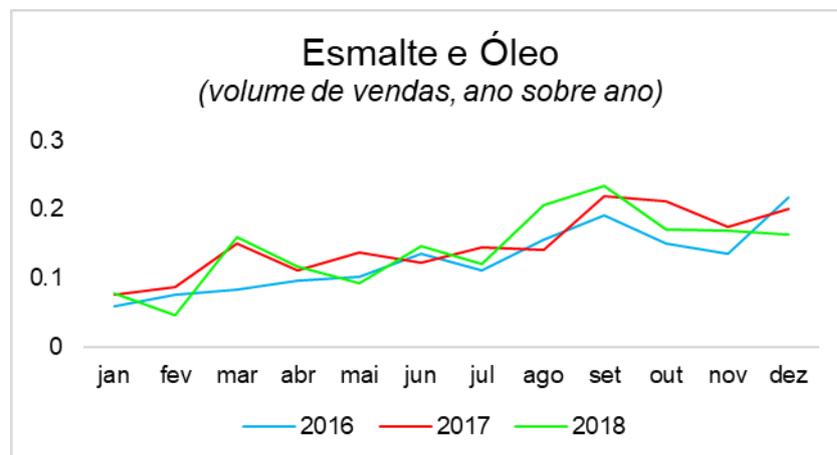
Na Figura 6, se percebe que esta série é marcada por uma maior oscilação do que as observadas anteriormente no capítulo. Devido a essa alta variação, a observação de algum padrão de sazonalidade é dificultada, mesmo ao observar a série sobreposta apresentada na Figura 7.

Figura 6 – Representação gráfica de evolução do volume de vendas da linha de produto esmalte e óleo



Fonte: O autor (2020)

Figura 7 – Representação gráfica da sobreposição entre as séries anuais da linha esmalte e óleo



Fonte: O autor (2020)

O componente de tendência também não fica claro com a simples observação dos volumes totais anuais. Através da Tabela 7, é perceptível um aumento ao longo dos três anos: 13% de aumento no volume total entre 2016 e 2018; mas o aumento das vendas em 2017 com queda relativa no ano seguinte pode indicar um padrão que só seria confirmado com acesso às séries de mais anos históricos.

Tabela 7 – Volume de vendas anual da linha esmalte e óleo

Ano	Volume vendido
2016	1,5
2017	1,8
2018	1,7

Fonte: O autor (2020).

5 RESULTADOS

Nesta seção são apresentados os resultados obtidos nos *outputs* do código em R para as linhas de produtos apresentadas no Capítulo 4. O código foi programado para executar os seis modelos de previsão de demanda supracitados em cada uma das linhas de produtos. Ele retorna a previsão de demanda para três meses e uma tabela de métricas de erro para a previsão de cada modelo em relação ao período de teste fornecido.

As métricas de erro do MAE permitem a comparação entre a acurácia dos modelos e a consequente escolha do modelo mais adequado para cada série.

No presente capítulo, serão consideradas as abreviações indicadas na Tabela 8 para se referir a cada modelo de previsão.

Tabela 8 – Lista de abreviações para os modelos de previsão de demanda

Abreviação	Modelo correspondente
AES	Amortecimento Exponencial Simples
AED	Amortecimento Exponencial Duplo (Método de Holt)
AET	Amortecimento Exponencial Triplo (Método de Holt-Winters)
DC	Decomposição Clássica
STL	Decomposição STL (<i>Seasonal and Trend Decomposition Using Loess</i>)
ARIMA	ARIMA (<i>Autoregressive Integrated Moving Average</i>)

Fonte: O autor (2020)

Além das abreviações para os modelos de previsão, é chamada de *Real* a série de teste, como será possível observar nas tabelas e gráficos ao longo da seção.

As previsões obtidas com cada um dos modelos para as linhas de produtos estão listadas nas Tabelas 9 (a), (b) e (c) para as linhas Látex, Massas e Esmalte e Óleo, respectivamente.

Tabela 9 (a) – Tabela de previsões para a linha látex

Período	Real	AES	AED	AET	DC	STL	ARIMA
Jan/2019	0,48	0,95	0,97	0,41	0,41	0,41	0,45
Fev/2019	0,43	0,95	0,99	0,37	0,36	0,35	0,28
Mar/2019	0,64	0,95	1,00	0,53	0,51	0,52	0,54

Fonte: O autor (2020)

Tabela 9 (b) – Tabela de previsões para a linha massas

Período	Real	AES	AED	AET	DC	STL	ARIMA
Jan/2019	0,15	0,31	0,32	0,06	0,09	-0,04	0,07
Fev/2019	0,21	0,31	0,33	0,11	0,12	0,07	0,12
Mar/2019	0,25	0,31	0,33	0,22	0,24	0,23	0,21

Fonte: O autor (2020)

Tabela 9 (c) – Tabela de previsões para a linha esmalte e óleo

Período	Real	AES	AED	AET	DC	STL	ARIMA
Jan/2019	0,09	0,17	0,18	0,09	0,07	0,08	0,08
Fev/2019	0,12	0,17	0,18	0,08	0,07	0,07	0,05
Mar/2019	0,13	0,17	0,18	0,14	0,14	0,14	0,16

Fonte: O autor (2020)

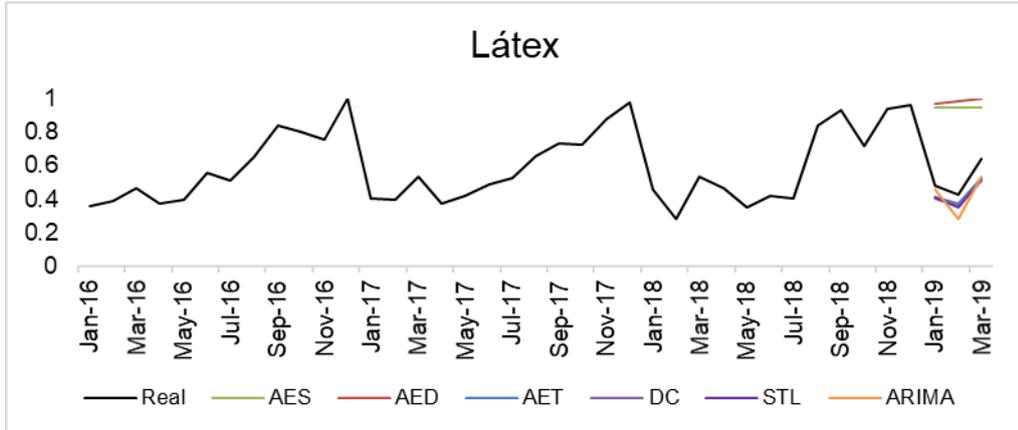
É perceptível que os modelos AES e AED tiveram um comportamento destoante dos demais modelos, com desempenho pior e previsões distantes do resultado real. Esse baixo desempenho se repete para as todas as linhas de produto.

Uma possível explicação para esse mau ajuste relaciona-se à presença de certo nível de sazonalidade e oscilação em todas as séries. Os amortecimentos exponenciais simples e duplos, como explicado na Fundamentação Teórica, não consideram a sazonalidade em sua previsão, sendo assim inadequados para a realidade da indústria de tintas e vernizes. Além disso, os amortecimentos exponenciais tendem a tomar o passado recente como mais influente para as previsões.

O comportamento dos modelos AES e AED é também visualmente evidenciado, como se observa nas Figuras 8 (a), (b) e (c), onde encontram-se plotadas as séries temporais para as linhas de produtos, seguidas das previsões obtidas. Cada modelo é representado nos gráficos por um tipo diferente de linha pontilhada, enquanto a série de teste está representada pela linha contínua, permitindo uma comparação visual das previsões.

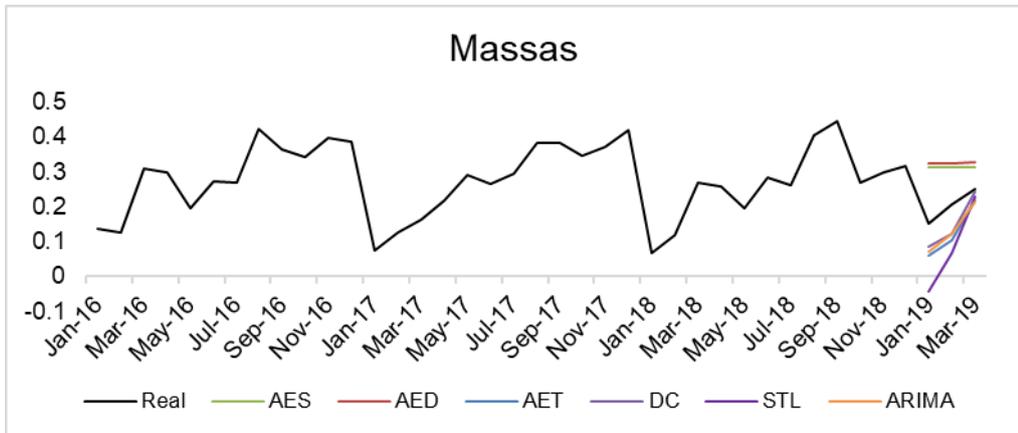
Nos gráficos, a influência dos valores mais recentes somada à ausência do fator de sazonalidade fica evidenciada pelo comportamento das previsões AES e AED, que vêm como uma continuação do último ponto da série de treino. O AES como uma linha reta constante, e o AED como uma linha influenciada também pela tendência. A seguir, gráficos das séries históricas e suas previsões nas Figuras 8, e visão detalhada das previsões nas Figuras 9.

Figura 8 (a) – Representação gráfica da série histórica da linha látex e suas previsões



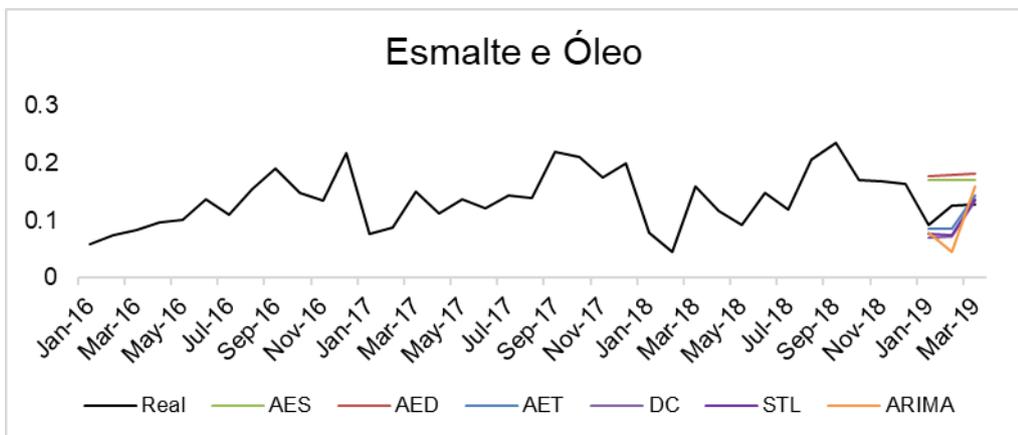
Fonte: O autor (2020)

Figura 8 (b) – Representação gráfica da série histórica da linha massas e suas previsões



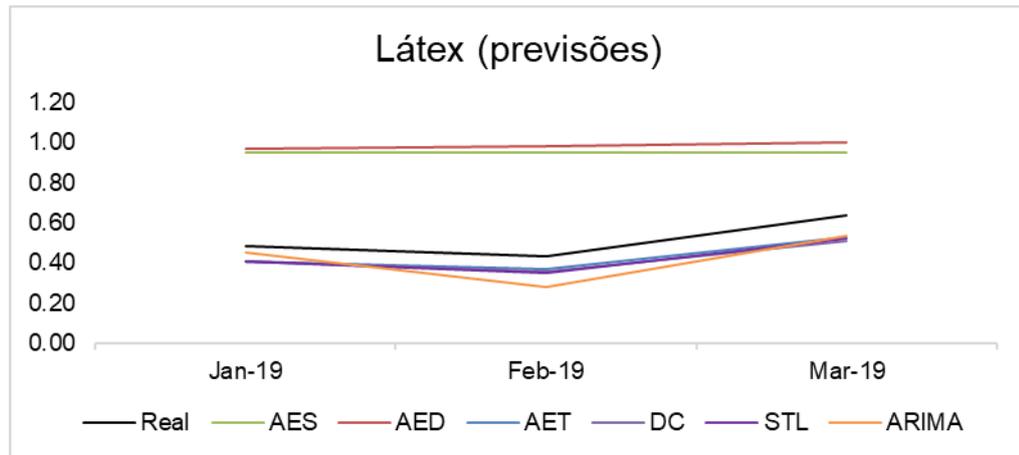
Fonte: O autor (2020)

Figura 8 (c) – Representação gráfica da série histórica da linha esmalte e óleo e suas previsões



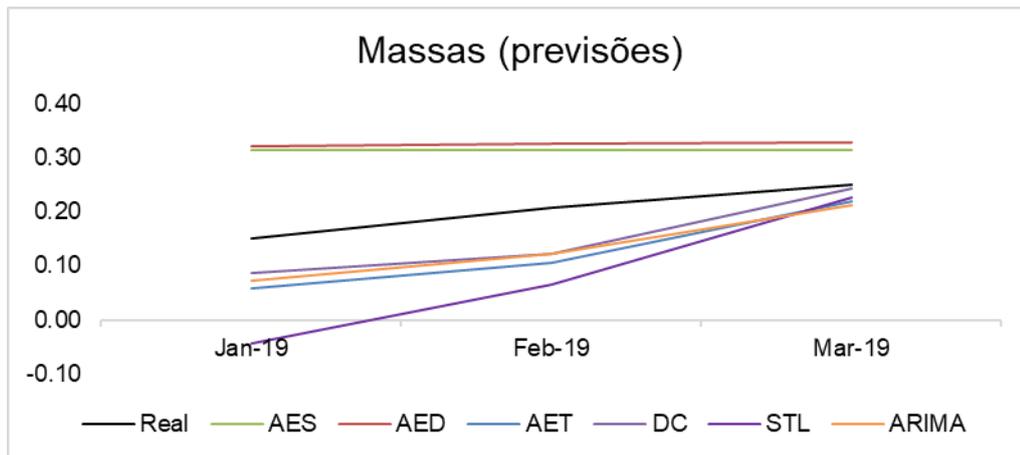
Fonte: O autor (2020)

Figura 9 (a) – Representação gráfica da previsão para a linha látex



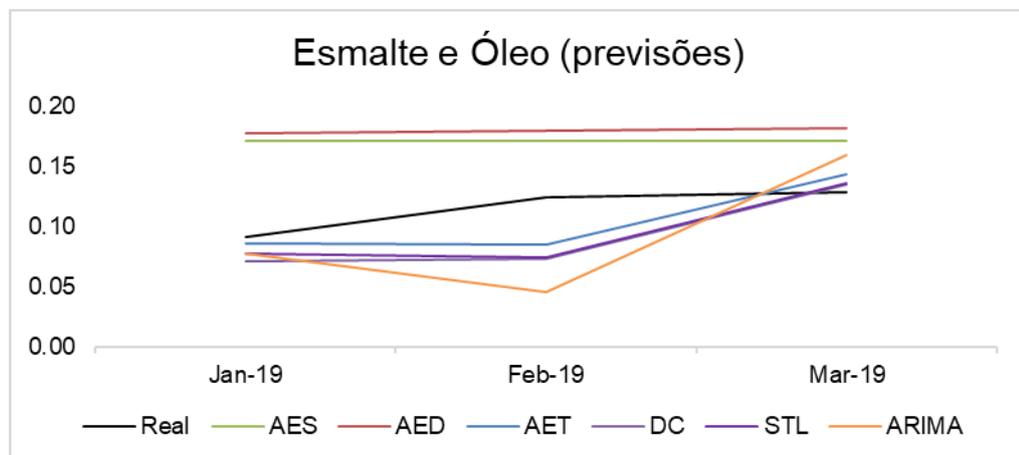
Fonte: O autor (2020)

Figura 9 (b) – Representação gráfica da previsão para a linha massas



Fonte: O autor (2020)

Figura 9 (c) – Representação gráfica da previsão para a linha esmalte e óleo

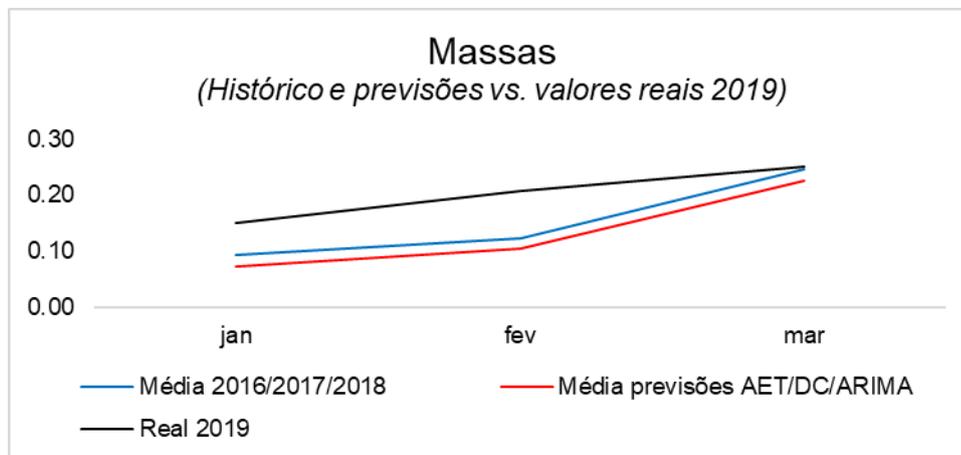


Fonte: O autor (2020)

Nas linhas Massas e Esmalte e Óleo, representadas nas Figuras 8 (b) e (c), percebe-se que os resultados obtidos estão relativamente distantes da série real. Ao observar as séries históricas, fica claro que o erro dos modelos na previsão é devido a um comportamento real diferente do observado no mesmo mês para os anos de 2017 e 2018. Como os modelos de previsão se baseiam no passado para realizar as estimativas futuras, variações reais causadas por fatores externos inesperados não são levadas em consideração pelos modelos.

Para evidenciar o comportamento dos modelos, do histórico e dos valores reais, é trazida a Figura 10, que sobrepõe a média nos três primeiros anos, a média das previsões AET, DC e ARIMA e o valor real para os meses de janeiro, fevereiro e março.

Figura 10 – Comparação entre a média histórica mensal, a previsão e os valores reais de 2019 (linha massas)



Fonte: O autor (2020)

No gráfico, observa-se um comportamento semelhante entre as previsões e a média histórica, com valores reduzidos devido à tendência de queda da linha Massas, descrita na seção anterior. Fica claro que os modelos seguiram a lógica proposta, mas que a realidade foi influenciada por fatores externos.

Esses erros são compreensíveis e justificados, especialmente porque as previsões nunca serão um retrato fiel do futuro, mas meramente uma estimativa baseada em histórico. Entretanto, é importante frisar que, apesar de justificados, esses erros poderiam provocar na empresa um grande problema na cadeia de suprimento caso não haja um plano adequado de contingência.

Como mencionado no início deste trabalho, a empresa em questão faz os pedidos de compra a cada três meses devido ao *lead time* dos fornecedores. Se a empresa fosse tomar as previsões como verdade absoluta, ela teria uma quebra no estoque de matéria-prima e a

produção provavelmente seria interrompida. Por isso é importante que a inteligência da empresa também acompanhe as tendências de mercado para garantir uma resposta rápida a esse tipo de flutuação. Além disso, é também importante manter uma política de estoques adequada para amortecer o impacto de demandas acima do previsto.

Na Figura 8 (c), referente à linha Esmalte e Óleo, pode-se ver que as previsões do modelo ARIMA replicam o comportamento do mesmo trimestre do ano anterior, estimando haver uma queda acentuada para o mês de fevereiro que não se repetiu na realidade, impactando na qualidade da previsão.

A qualidade da previsão dos modelos é melhor entendida através das Tabelas 5.3 (a), (b) e (c), que trazem o ranqueamento dos MAE dos modelos de previsão para cada linha de produtos. Através dessa comparação, é possível escolher o modelo para realizar as previsões de curto prazo daquela linha.

Tabela 10 - Tabela de ranqueamento do erro das previsões

(A) LÁTEX		(B) MASSAS		(C) ESMALTE E ÓLEO	
Modelo	MAE	Modelo	MAE	Modelo	MAE
AET	0,084	DC	0,062	AET	0,025
STL	0,093	ARIMA	0,070	STL	0,031
DC	0,095	AET	0,082	DC	0,032
ARIMA	0,107	AES	0,118	ARIMA	0,050
AES	0,440	AED	0,129	AES	0,058
AED	0,476	STL	0,140	AED	0,067

Fonte: O autor (2020)

Nas tabelas, os menores valores representam a melhor previsão. Dessa forma, as séries escolhidas para cada uma das linhas de produtos selecionadas são apresentadas na Tabela 11. O modelo AET foi o que apresentou melhor desempenho geral, exceto pela linha Massas, que contou com o comportamento real mais inusitado para 2019 e resultou no modelo DC.

Tabela 11 – Resumo dos resultados

Linha de produto	Modelo de previsão selecionado
Látex	AET
Massas	DC
Esmalte e Óleo	AET

Fonte: O autor (2020)

6 CONCLUSÃO

Esta pesquisa visava selecionar modelos de previsão de demanda para as séries temporais das linhas de produtos da empresa. Para isso, foi necessário o tratamento das séries, agrupando-as, em seguida a aplicação dos modelos de previsão em linguagem R e, a partir dos outputs da execução, a realização de uma análise comparativa dentre os modelos para cada linha de produtos.

Apesar de o algoritmo não ter sido implementado à empresa após seu desenvolvimento, este trabalho foi conduzido considerando o contexto real da empresa, seus valores e suas necessidades, e está disponível para uso pela mesma.

O trabalho parte da base de dados fornecida pela empresa, agrupando as informações mensalmente, e resumindo os produtos a suas linhas. As informações foram então normalizadas, concluindo assim a etapa de tratamento dos dados.

O algoritmo desenvolvido em R aplicou os modelos de previsão selecionados sobre as linhas de produto, gerando as tabelas de MAE que permitiram a comparação do desempenho dos modelos para cada linha. Por fim, os modelos com melhor desempenho foram apontados, sendo selecionados o Amortecimento Exponencial Triplo e a Decomposição Clássica como os mais adequados para as séries temporais das linhas Látex, Massas e Esmalte e Óleo.

Esta pesquisa permitiu a comparação do desempenho entre as previsões geradas pelos modelos selecionados, tal como previsto em seus objetivos. Entretanto, há diferentes formas de continuar o desenvolvimento da pesquisa, tanto para obter estimativas mais precisas quanto para permitir novos *insights* sobre a indústria e suas correlações com o mercado.

6.1 LIMITAÇÕES E TRABALHOS FUTUROS

Corrêa & Corrêa (2012) pontuam que a modelagem se torna melhor quando dispõe de um maior histórico de dados. Assim sendo, o ajuste dos modelos poderia se beneficiar de uma maior quantidade de pontos na série de dados de treinamento, ou seja, de mais anos sobre os quais embasar-se.

Quanto ao algoritmo em si, foi utilizada a função *auto.arima* (), que é a forma mais simples de implementação do modelo ARIMA em R. Por fazer aproximações para reduzir o tempo de execução, essa função corre o risco de não encontrar o melhor ajuste. O uso da função *Arima* (), fazendo as devidas transformações dos dados, analisando a ACF e eliminando resíduos no passo-a-passo, pode trazer previsões com maior precisão.

Outra possível melhoria ao método proposto seria incluir restrições para os valores das previsões ao se implementar os modelos. Foi observado que a previsão STL da linha Massas gerou um valor negativo para o mês de janeiro, o que é um volume irreal de vendas. A inclusão de uma restrição indicando que o valor mínimo é zero poderia prevenir essa ocorrência que acarretou na pior performance do STL na tabela MAE da linha.

Assim como feito por Soy Temür, Akgün & Temür (2019), a implementação de um modelo híbrido de previsão, combinando modelos lineares a outros mais sofisticados e modernos, como algoritmos de aprendizagem de máquina, tem o potencial de gerar resultados com melhor ajuste. A seleção de um modelo não-linear para combinar ao AET ou ao ARIMA pode ser uma evolução pertinente ao estudo.

Por fim, como abordado na discussão dos resultados, os modelos apresentaram um problema de desempenho quando as séries reais apresentaram um comportamento destoante, provavelmente causado por uma externalidade. Os modelos deste trabalho não foram implementados considerando qualquer influência que não a série histórica de dados da própria linha de produtos. Uma forma de entender essas influências externas poderia ser através do estudo cruzado das séries temporais do mercado imobiliário, de materiais de construção ou da economia nacional para buscar correlações, ou com a inclusão de variáveis exógenas ao modelo com o uso de ARIMAX ou outros semelhantes.

REFERÊNCIAS

- CHATFIELD, Chris. **The Analysis of Time Series - An Introduction**. 5ª ed. University of Bath, United Kingdom: Chapman & Hall/CRC, 1996.
- CLEVELAND, R. B.; CLEVELAND, W. S.; MCRAE, J. E., TERPENNING, I. J. STL: A seasonal-trend decomposition procedure based on loess. **Journal of Official Statistics**, v. 6, n. 1, p. 3–33, 1990.
- CORREA, Henrique L. & CORREA, Carlos A. **Administração de Produção e Operações - Manufatura e serviços: uma abordagem estratégica**. – 3 ed. São Paulo, Atlas, 2012.
- DOANE, D. P.; SEWARD, L. E. **Estatística aplicada à administração e economia**. 4.ed. Porto Alegre, AMGH, 2014.
- GIL, A. C. **Métodos e técnicas de pesquisa social**. 5.ed. São Paulo: Atlas, 1999.
- GRIMSON, J. A.; PYKE, D. F. Sales and operations planning: an exploratory study and framework. **The International Journal of Logistics Management**, v. 18, n. 3, p. 322–346, 2007. DOI:10.1108/09574090710835093
- HOLT, C. E. **Forecasting seasonals and trends by exponentially weighted averages** (O.N.R. Memorandum No. 52). Pittsburgh, Carnegie Institute of Technology, 1957. DOI: 10.1016/j.ijforecast.2003.09.015
- HYNDMAN, R. A brief history of forecasting competitions. **International Journal of Forecasting**, v. 36, n. 1, p. 7-14, 2019. DOI:10.1016/j.ijforecast.2019.03.015
- HYNDMAN, R.; ATHANASOPOULOS, G. **Forecasting: principles and practice**, 2 ed. Melbourne, Australia: OTexts, 2018.
- HYNDMAN, R.; KOEHLER, A.; SNYDER, R.; GROSE, S. A state space framework for automatic forecasting using exponential smoothing methods. **International Journal of Forecasting**, v. 18, p. 439–454, 2002.
- LISPECTOR, Clarice. **A hora da estrela**. Rio de Janeiro: Editora Rocco, 1998.
- MAKRIDAKIS, S.; HIBON, M. The M3-Competition: results, conclusions and implications. **International Journal of Forecasting**, v. 16, n. 4, p. 451–476, 2000.
- MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to time series analysis and forecasting**. John Wiley & Sons, 2015.
- MOREIRA, D. A. **Administração da Produção e Operações**. 2 ed. São Paulo, Cengage Learning, 2015.
- SOUZA, A. G.; GIANEZINI, M.; WATANABE, M. Panorama do Setor de Tintas no Brasil: Mercado, Gestão e Tecnologias para o Segmento de Tintas Imobiliárias. **Revista Geintec**, Aracaju, SE, Vol.8, n.3: p.4430-4446, 2018. DOI: 10.7198/geintec.v8i3.1110

SOTO-FERRARI, M.; CHAMS-ANTURI, O.; ESCORCIA-CABALLERO, J. P.; HUSSAIN, N.; KHAN, M. Evaluation of Bottom-Up and Top-Down Strategies for Aggregated Forecasts: State Space Models and ARIMA Applications. In: PATERNINA-ARBOLEDA, C.; VOß, S. (org) **Computational Logistics**. Barranquilla, Colombia: Springer, 2019. p. 413–427. DOI: 10.1007/978-3-030-31140-7_26

SHINGO, S. **O Sistema Toyota de Produção do ponto de vista da Engenharia de Produção**. 2 ed. Porto Alegre: Artes Médicas, 1996.

SOY TEMÜR, A.; AKGÜN, M.; TEMÜR, G. Predicting housing sales in Turkey using ARIMA, LSTM and hybrid models. **Journal of Business Economics and Management**, v. 20, n. 5, p. 920-938. 2019. DOI: 10.3846/jbem.2019.10190

APÊNDICE A – ALGORITMO IMPLEMENTADO

Este apêndice apresenta o algoritmo implementado neste trabalho. É importante observar que a base de dados não pôde ser fornecida para preservar a confidencialidade da empresa detentora dos dados, mas ele pode ser aplicado para outras séries a partir do Excel, modificando o nome do arquivo onde está indicado com “nome_do_seu_arquivo.xlsx” no código.

```
## Instala e carrega bibliotecas necessárias para rodar o código
list.of.packages <- c("plyr", "zoo", "dplyr", "forecast", "rlist",
"forecastHybrid", "XLConnect", "rJava", "tidyverse", "caTools", "fpp2")

new.packages <- list.of.packages[!(list.of.packages %in% installed.packages()[,"Package"])
if(length(new.packages)) install.packages(new.packages)

invisible(lapply(list.of.packages, require, character.only = TRUE))

library(forecast)
library(fpp2)
library(tidyverse)
library(readxl)
library(XLConnect)

#Sys.setenv(JAVA_HOME="")

## importando base de dados do Excel
BD <- read_excel("nome_do_seu_arquivo.xlsx", col_types = c("date",
"numeric", "numeric", "numeric", "numeric",
"numeric", "numeric", "numeric", "numeric",
"numeric"))

View(BD)

'## Transforma BD em serie temporal
tsBD <- ts(BD, frequency=12, start = 1)'
```

```

## Tamanho da serie total
nDados <- nrow(tsBD)
## Período a ser previsto
nPrev <- 3
anoInicio <- 2016
anoPrevisao <- 2019
## Tamanho da serie de treino
nTreino <- nDados - nPrev
## Início da serie de teste
nTeste <- nTreino + 1

## Cria dieretorios para salvar testes
Pasta <- getwd()
horaRodada <- gsub(":"|"|" , "_" , as.character(Sys.time()))
resultados <- paste0(Pasta,"/Testes/" , horaRodada, "/")
resultadosGraficos <- paste0(resultados, "Graficos/")
if (!dir.exists(resultadosGraficos)) dir.create(resultadosGraficos, recursive = T)

## Cria bases de output
BasePrevisaoFinal <- data.frame(Periodo = as.yearmon(as.numeric()), Serie = character(),
                               prev1 = numeric(), prev2 = numeric(), prev3 = numeric(),
                               metodo1 = numeric(), metodo2 = numeric(), metodo3 = numeric(),
                               stringsAsFactors = FALSE)

BaseBacktestFinal <- data.frame(Periodo = as.yearmon(as.numeric()), Serie = character(),
                               prev1 = numeric(), prev2 = numeric(), prev3 = numeric(),
                               metodo1 = numeric(), metodo2 = numeric(), metodo3 = numeric(),
                               stringsAsFactors = FALSE)

BaseAvaliacaoFinal <- data.frame(Serie = character(), Ranking = character(),
                                testeInicio = as.yearmon(as.numeric()), testeFim =
                                as.yearmon(as.numeric()),
                                metodo = numeric(), ME = numeric(), MAE = numeric(),
                                RMSE = numeric(), MAPE = numeric(), MASE = numeric(),

```

```

stringsAsFactors = FALSE)

## Início do loop por série
for (i in 2:ncol(BD)){
  #i = 3
  #print(i)
  ## Define linha de produtos
  bdSubset <- BD %>% select(i)
  tsSubset <- ts(bdSubset, frequency=12, start = anoInicio)
  ls.ts.teste <- list()

  ## Define series de treino, teste (últimos 3 meses) e previsao
  tsBaseTreino <- ts(tsSubset[1:nTreino], frequency=12, start = anoInicio)
  tsBaseTeste <- ts(tsSubset[(nTeste):length(tsSubset)], frequency = 12, start = anoPrevisao)
  tsPrevisao <- ts(tsSubset[(nTeste):length(tsSubset)], frequency = 12, start = anoPrevisao)

  BasePrevInSample <- tsBaseTeste
  #BasePrevInSample <- NA

  # Prepara MAE naive para calculo dos MASE
  BaseNaive <- BasePrevInSample

  BaseNaive[1] <- tsBaseTreino[length(tsBaseTreino)]
  for (j in 2:length(BaseNaive)) {
    print(j)
    BaseNaive[j] <- tsBaseTeste[j-1]

    #print(BaseNaive[j])
  }
  MAE_Naive <- accuracy(BaseNaive, tsBaseTeste)[3]

  # Gera base de dados para armazenamento das previsoes
  Modelos <- data.frame(Metodo = character(), ME = numeric(), MAE = numeric(), RMSE =
numeric(), MAPE = numeric(), MASE = numeric(), Ranking = integer())

```

```

ModelosAux1 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1))
ModelosAux2 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1))
ModelosAux3 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1))
ModelosAux4 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1))
ModelosAux5 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1))
ModelosAux6 <- data.frame(Metodo = character(1), ME = numeric(1), MAE = numeric(1),
RMSE = numeric(1), MAPE = numeric(1), MASE = numeric(1), ACF1 = numeric(1))
dfBacktest <- NULL
tsTreinoTeste <- ts(c(tsBaseTreino, tsBaseTeste), start = start(tsBaseTreino), frequency =
frequency(tsBaseTreino))
tsPrevisaoAuxiliar <- tsPrevisao
tsPrevisao <- NULL

# 1 --- Amortecimento Exponencial Simples (AES)
# Teste
AES <- ses(tsBaseTreino, h=nPrev, initial = "optimal")
ModelosAux$Metodo <- "AES"

ModelosAux1$ME <- accuracy(AES,tsBaseTeste)[2]
ModelosAux1$RMSE <- accuracy(AES,tsBaseTeste)[4]
ModelosAux1$MAE <- accuracy(AES,tsBaseTeste)[6]
ModelosAux1$MAPE <- accuracy(AES,tsBaseTeste)[10]
ModelosAux1$MASE <- accuracy(AES,tsBaseTeste)[12]

# 2 --- Amortecimento Exponencial Duplo (AED) - Holt
# Teste
AED <- holt(tsBaseTreino, h=nPrev, initial = "optimal")
ModelosAux2$Metodo <- "AED"
ModelosAux2$ME <- accuracy(AED,tsBaseTeste)[2]

```

```

ModelosAux2$RMSE <- accuracy(AED,tsBaseTeste)[4]
ModelosAux2$MAE <- accuracy(AED,tsBaseTeste)[6]
ModelosAux2$MAPE <- accuracy(AED,tsBaseTeste)[10]
ModelosAux2$MASE <- accuracy(AED,tsBaseTeste)[12]

# 3 --- Amortecimento Exponencial Triplo (AET) - Holt-Winters
if (length(tsBaseTreino)>=15) {

  # Teste
  AET <- hw(tsBaseTreino, h=nPrev, initial = "optimal")
  ModelosAux3$Metodo <- "AET"
  ModelosAux3$ME <- accuracy(AET,tsBaseTeste)[2]
  ModelosAux3$RMSE <- accuracy(AET,tsBaseTeste)[4]
  ModelosAux3$MAE <- accuracy(AET,tsBaseTeste)[6]
  ModelosAux3$MAPE <- accuracy(AET,tsBaseTeste)[10]
  ModelosAux3$MASE <- accuracy(AET,tsBaseTeste)[12]
}

# 4 --- Decomposição Clássica
mDC <- ets(tsBaseTreino)
DC <- forecast(mDC, h=nPrev)

ModelosAux4$Metodo <- "DC"
ModelosAux4$ME <- accuracy(DC,tsBaseTeste)[2]
ModelosAux4$RMSE <- accuracy(DC,tsBaseTeste)[4]
ModelosAux4$MAE <- accuracy(DC,tsBaseTeste)[6]
ModelosAux4$MAPE <- accuracy(DC,tsBaseTeste)[10]
ModelosAux4$MASE <- accuracy(DC,tsBaseTeste)[12]

# 5 --- Seasonal Decomposition of Time Series by Loess
if (length(tsBaseTreino)>24) {

  mSTLoess <- stlm(tsBaseTreino, lambda = "auto", biasadj = TRUE)
  STLoess <- forecast(mSTLoess, h=nPrev)
}

```

```

ModelosAux5$Metodo <- "STLoess"
ModelosAux5$ME <- accuracy(STLoess,tsBaseTeste)[2]
ModelosAux5$RMSE <- accuracy(STLoess,tsBaseTeste)[4]
ModelosAux5$MAE <- accuracy(STLoess,tsBaseTeste)[6]
ModelosAux5$MAPE <- accuracy(STLoess,tsBaseTeste)[10]
ModelosAux5$MASE <- accuracy(STLoess,tsBaseTeste)[12]
}

# 6 --- ARIMA
# Teste
mARIMA <- auto.arima(tsBaseTreino, lambda = "auto")
ARIMA <- forecast(mARIMA, h=nPrev)

ModelosAux6$Metodo <- "ARIMA"
ModelosAux6$ME <- accuracy(ARIMA,tsBaseTeste)[2]
ModelosAux6$RMSE <- accuracy(ARIMA,tsBaseTeste)[4]
ModelosAux6$MAE <- accuracy(ARIMA,tsBaseTeste)[6]
ModelosAux6$MAPE <- accuracy(ARIMA,tsBaseTeste)[10]
ModelosAux6$MASE <- accuracy(ARIMA,tsBaseTeste)[12]
ModelosAux6$ACF1 <- accuracy(ARIMA,tsBaseTeste)[13]

cont = cont+1
print (cont)
print(names(BD)[i])
print(ModelosAux1)
print(AES)
print(ModelosAux2)
print(AED)
print(ModelosAux3)
print(AET)
print(ModelosAux4)
print(DC)
print(ModelosAux5)
print(STLoess)

```

```
print(ModelosAux6)
print(ARIMA)
}
```