

FELIPE DE OLIVEIRA PIMENTA

**PREVISÃO DE DEMANDA DE UMA EMPRESA VAREJISTA DE VINHOS POR
MEIO DE MÉTODOS QUANTITATIVOS**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de São
Paulo para obtenção do Diploma de
Engenheiro de Produção

São Paulo

2016

FELIPE DE OLIVEIRA PIMENTA

**PREVISÃO DE DEMANDA DE UMA EMPRESA VAREJISTA POR MEIO DE
MÉTODOS QUANTITATIVOS**

Trabalho de Formatura apresentado à
Escola Politécnica da Universidade de São
Paulo para obtenção do Diploma de
Engenheiro de Produção

Orientador: Prof. Dr. Álvaro Euzébio
Hernandez

São Paulo

2016

FICHA CATALOGRÁFICA

Pimenta, Felipe de Oliveira

Previsão de demanda de uma empresa varejista de vinhos por meio de métodos quantitativos / F. O. Pimenta -- São Paulo, 2016.
101 p.

Trabalho de Formatura - Escola Politécnica da Universidade de São Paulo. Departamento de Engenharia de Produção.

1.Demanda 2.Modelo em séries temporais I.Universidade de São Paulo.
Escola Politécnica. Departamento de Engenharia de Produção II.t.

À minha mãe, pelo apoio incondicional.

À minha avó, pelas batalhas vencidas.

AGRADECIMENTOS

Agradeço à minha mãe, por ser um exemplo e um porto onde sempre encontrei abrigo, à minha avó, Djanira, pelo amor e cuidado demonstrado ao longo de todos esses anos.

Agradeço ao meu pai pelos conselhos dados e os momentos felizes que passamos juntos. À minha avó Ana, pela preocupação e agrados recebidos desde criança.

Agradeço aos meus irmãos, Gabriela, Gustavo e Lucas pela felicidade que colocaram em meu coração, pelas brincadeiras e risos que fazem a vida valer a pena.

Agradeço à Carol, por estar ao meu lado nos momentos em que eu duvidei se seria capaz, pelo amor sincero e verdadeiro e por me aturar em situações que eu não me aturaria.

Finalmente agradeço ao meu orientador, Professor Álvaro, pela paixão e dedicação à profissão e pelos ensinamentos que levarei comigo.

Se és capaz de dar, segundo por segundo,

ao minuto fatal todo valor e brilho.

Tua é a Terra com tudo o que existe no mundo.

(Rudyard Kipling)

RESUMO

A previsão de demanda é essencial para um processo de tomada de decisões eficaz e coerente. Sem essa ferramenta, problemas como altos níveis de estoque, falta de produtos chave e perda de clientes, se tornam muito mais prováveis. Isso promove uma desestruturação em diversos processos dentro de uma empresa, impactando, inclusive, todo o planejamento realizado. O presente trabalho, portanto, se propõe a aplicar métodos quantitativos de previsão de demanda em séries temporais em uma empresa varejista nacional. Primeiramente, buscouse compreender o problema enfrentado pela empresa, para, em seguida, procurar na literatura os métodos tradicionalmente utilizados, suas particularidades e objetivos. Os produtos foram agrupados em três diferentes famílias, para então, aplicar os métodos quantitativos de previsão de demanda em séries temporais na empresa por meio da construção de um modelo. A análise dos resultados indicou que os métodos de Holt-Winters com sazonalidade multiplicativa e suavização exponencial com tendência apresentaram erros até 73% menor do que o método utilizado pela empresa. Foi possível concluir que prever a demanda dos produtos da empresa pode resultar em uma grande vantagem competitiva, facilitando e aprimorando a tomada de decisões.

Palavras-chave: Previsão de demanda. Séries temporais.

ABSTRACT

Demand forecasting is essential for an effective and consistent decision making process. Without this tool, some problems are more likely to happen, such as high stock levels, products shortage and loss of customers. This promotes a breakdown in a lot of process inside a company and can impact the entire planning made. This study intends to apply a quantitative demand forecasting method by time series analysis in a national company. First, the study explored the problem faced by the company to, then, search in the literature the methods that are traditionally used, with their characteristics and objectives. The products were grouped in three different families, to then apply the quantitative methods of demand forecasting by time series in the company through the construction of a model. The analysis of the results indicated that the Holt-Winters methods with multiplicative seasonality and exponential smoothing trend presented errors up to 73% lower than the method used by the company. It was concluded that making a demand forecasting for the company's products can result in a great competitive advantage, that could facilitate and improve decision-making process.

Keywords: Demand forecasting. Time series.

LISTA DE FIGURAS

Figura 1-1- Organograma da VinhosCo	27
Figura 2-1- Framework para prever e planejar.....	39
Figura 3-1- Fases de um modelo de previsão.....	63
Figura 3-2- Processo de previsão de demanda	64
Figura 4-1- Aplicação do método de médias móveis	75
Figura 4-2- Aplicação do método de suavização exponencial simples.....	76
Figura 4-3- Parametrização do Solver.....	76
Figura 4-4- Aplicação do método de suavização exponencial com tendência.....	77
Figura 4-5- Fases do modelo de suavização exponencial com sazonalidade.....	78
Figura 4-6- Aplicação do método de suavização exponencial com sazonalidade	79
Figura 4-7- Fases do modelo de Holt-Winters	79
Figura 4-8- Aplicação do método de suavização exponencial com tendência e sazonalidade multiplicativa	80
Figura 4-9- Aplicação do método de suavização exponencial com tendência e sazonalidade aditiva.....	81

LISTA DE GRÁFICOS

Gráfico 1-1- Representatividade do faturamento por unidade de negócios	28
Gráfico 1-2- Consumo per capita anual, em litros (2015).....	29
Gráfico 1-3- Volume importado de vinhos no Brasil em milhões de litros	29
Gráfico 1-4- Evolução da representatividade por unidade de negócio	30
Gráfico 1-5- Crescimento da receita bruta com base 100	31
Gráfico 1-6- Dias de estoque.....	32
Gráfico 1-7- Quantidade de garrafas de espumantes vendidas	34
Gráfico 1-8- Giro do estoque atual por faixa de preço em anos.....	35
Gráfico 3-1- Lead Time médio de produtos por origem	61
Gráfico 3-2- Quantidade de SKUs por tipo de vinho	66
Gráfico 3-3- Representatividade do faturamento por tipo de vinho.....	66
Gráfico 3-4- Representatividade acumulada por SKU de vinhos tintos sobre o seu faturamento total	67
Gráfico 3-5- Representatividade acumulada por SKU de vinhos brancos sobre o seu faturamento total	68
Gráfico 3-6-Representatividade acumulada por SKU de espumantes sobre o seu faturamento total	68
Gráfico 3-7- Demanda dos Tintos-A (quantidade de garrafas) por mês	70
Gráfico 3-8- Demanda dos Brancos-A (quantidade de garrafas) por mês	71
Gráfico 3-9- Demanda dos Espumantes-A em quantidade de SKU por mês.....	72
Gráfico 5-1- MAPE dos Tintos-A por método.....	84
Gráfico 5-2- Resultado da previsão de Tintos-A utilizando o método de Holt-Winters com sazonalidade multiplicativa	85
Gráfico 5-3- MAPE dos Brancos-A por método.....	89
Gráfico 5-4- Resultado da previsão de Brancos-A utilizando o método linear de Holt....	90
Gráfico 5-5 MAPE dos Espumantes-A por método	93
Gráfico 5-6- Resultado da previsão de Espumantes-A utilizando o método de Holt- Winters com sazonalidade multiplicativa	94

LISTA DE TABELAS

Tabela 1-1- Planilha de análise de estoque	33
Tabela 5-1- Detalhes dos resultados obtidos para Tintos-A.....	85
Tabela 5-2- Análise de sensibilidade do MAPE para o método de Holt-Winters com sazonalidade multiplicativa para Tintos-A.....	87
Tabela 5-3- Detalhes dos resultados obtidos para Brancos-A.....	89
Tabela 5-4- Análise de sensibilidade do MAPE para o método linear de Holt para Brancos-A	92
Tabela 5-5- Detalhes dos resultados obtidos para Espumantes-A	93
Tabela 5-6- Análise de sensibilidade do MAPE para o método de Holt-Winters com sazonalidade multiplicativa para Espumantes-A	96

LISTA DE ABREVIATURA E SIGLAS

ERP *Enterprise Resource Planning*

MAE *Mean Absolute Error*

MAPE *Mean Absolute Percentage Error*

ME *Mean Error*

MPE *Mean Percentage Error*

MSE *Mean Squared Error*

PE *Percentage Error*

SKU *Stock Keeping Unit*

TI *Tecnologia da Informação*

SUMÁRIO

1	INTRODUÇÃO	25
1.1	Descrição do estágio	25
1.2	Descrição da empresa	26
	<i>1.2.1 Estrutura organizacional</i>	27
	<i>1.2.2 Análise de faturamento da empresa e dados de mercado.....</i>	28
1.3	Situação atual e problema a ser solucionado.....	31
	<i>1.3.1 Motivação para desenvolver o tema</i>	36
1.4	Objetivo do trabalho.....	36
2	REVISÃO DA LITERATURA	37
2.1	Por que prever?	37
2.2	Prever e planejar	38
2.3	Passos básicos para previsão.....	40
2.4	Acurácia	42
	<i>2.4.1 Erros de previsão</i>	42
2.5	Métodos qualitativos.....	44
2.6	Séries temporais	45
	<i>2.6.1 Visualização gráfica</i>	45
	<i>2.6.2 Principais séries temporais.....</i>	46
	<i>2.6.3 Transformações e ajustes.....</i>	47
	<i>2.6.4 Princípio de decomposição.....</i>	47

2.6.5	<i>Métodos de previsões para séries temporais</i>	49
2.7	Métodos causais	53
3	PREVISÃO DE DEMANDA DA VINHOS.CO	57
3.1	Softwares de previsão.....	57
<i>3.1.1</i>	<i>Escolha do software</i>	60
3.2	Estrutura do modelo.....	60
3.3	Processo de previsão de demanda	63
3.4	Levantamento de dados	64
3.5	Análise preliminar dos dados	69
<i>3.5.1</i>	<i>Tintos-A</i>	69
<i>3.5.2</i>	<i>Brancos-A</i>	70
<i>3.5.3</i>	<i>Espumantes-A</i>	71
4	MODELOS DE PREVISÃO DE DEMANDA NA VINHOS.CO	73
4.1	Modelo de Médias Móveis.....	74
4.2	Modelo de Suavização Exponencial Simples.....	75
4.3	Modelo de Suavização Exponencial com Tendência	76
4.4	Modelo de Suavização Exponencial com Sazonalidade	77
4.5	Modelo de Suavização Exponencial com Tendência e Sazonalidade Multiplicativa.....	79
4.6	Modelo de Suavização Exponencial com Tendência e Sazonalidade Aditiva ..	80
5	ANÁLISE DOS RESULTADOS	83
5.1	Tintos-A	83

5.2	Brancos-A	88
5.3	Espumantes-A	92
6	CONCLUSÃO	99
	REFERÊNCIAS	101

1 INTRODUÇÃO

O presente trabalho tem por objetivo a análise da previsão de demanda de uma empresa varejista. Por meio da aplicação de diversos métodos de previsão, buscou-se encontrar o método que melhor representa a curva de demanda das famílias de produtos da companhia.

Atualmente, o processo de previsão de demanda realizado pela empresa é praticamente inexistente e insuficiente para fornecer *outputs* necessários para o departamento de compras. Os erros advindos desse processo geram problemas como alto nível de inventário, quebra de inventário de produtos chave e erros de acurácia, impactando diretamente o fluxo de caixa da empresa, limitando investimentos em processos, sistemas e outras atividades que podem resultar em vantagens competitivas para a empresa.

A seguir será apresentada a empresa e o seu respectivo setor de atuação bem como particularidades dos produtos, comportamento de vendas e níveis de estoque. Posteriormente, será exposto o método atual de previsão de demanda da empresa, medidas de comparação com o setor, os objetivos deste trabalho e as dificuldades que este se propõe a resolver.

No capítulo dois será realizada a revisão da literatura, na qual serão apresentados conceitos-chave existentes na literatura necessários para o entendimento e desenvolvimento deste trabalho.

O capítulo três apresentará, baseado na revisão da literatura, os métodos utilizados no trabalho para a resolução do problema proposto.

O capítulo quatro apresentará os modelos que serão utilizados para a previsão de demanda da Vinhos.Co.

O capítulo cinco analisará os resultados obtidos para as diferentes famílias de produtos e o melhor método baseado no critério escolhido.

Finalmente, o capítulo seis apresentará a conclusão do trabalho e suas considerações finais.

1.1 Descrição do estágio

O autor iniciou o estágio na Vinhos.Co em fevereiro de 2016. Inicialmente, foi alocado para equipe de análises financeiras, onde realizava relatórios financeiros apresentados ao fundo controlador da empresa.

A Vinhos.Co apresentava uma necessidade latente para análises e estudos nos diferentes setores da companhia, capazes de fornecer informações suficientemente robustas para a tomada de decisões estratégicas pela alta gestão.

Com isso, a atuação passou da área financeira para análises dos diversos setores da empresa, iniciando por aqueles que desconfiavam serem as mais problemáticas.

Após diversas análises de portfólio, dimensionamento do estoque, giro dos principais *Stock Keeping Unit* (SKU) e processos de compras, foi possível diagnosticar problemas de grande relevância para o futuro da empresa.

Nas reuniões realizadas para apresentação dos resultados encontrados com o presidente da empresa, foi solicitado ao autor do trabalho que se dedicasse ao problema de previsão de demanda.

O autor permaneceu no estágio durante toda a elaboração do presente trabalho, possibilitando o desenvolvimento contínuo, a análise e o levantamento de todos os pontos pertinentes à sua elaboração.

1.2 Descrição da empresa

Com o intuito de facilitar a compreensão do trabalho, será realizada uma breve descrição da empresa e do setor de atuação, destacando suas principais características, processos, produtos e mercado.

Por questões de confidencialidade, a empresa onde foi realizado o trabalho será denominada pelo nome fictício de VinhosCo. Para garantir a segurança de informações estratégicas, foi utilizado um multiplicador para mascarar os dados utilizados. Entretanto, a utilização do fator não interfere nos resultados obtidos a partir das séries históricas, já que as particularidades como tendência e sazonalidade são mantidas.

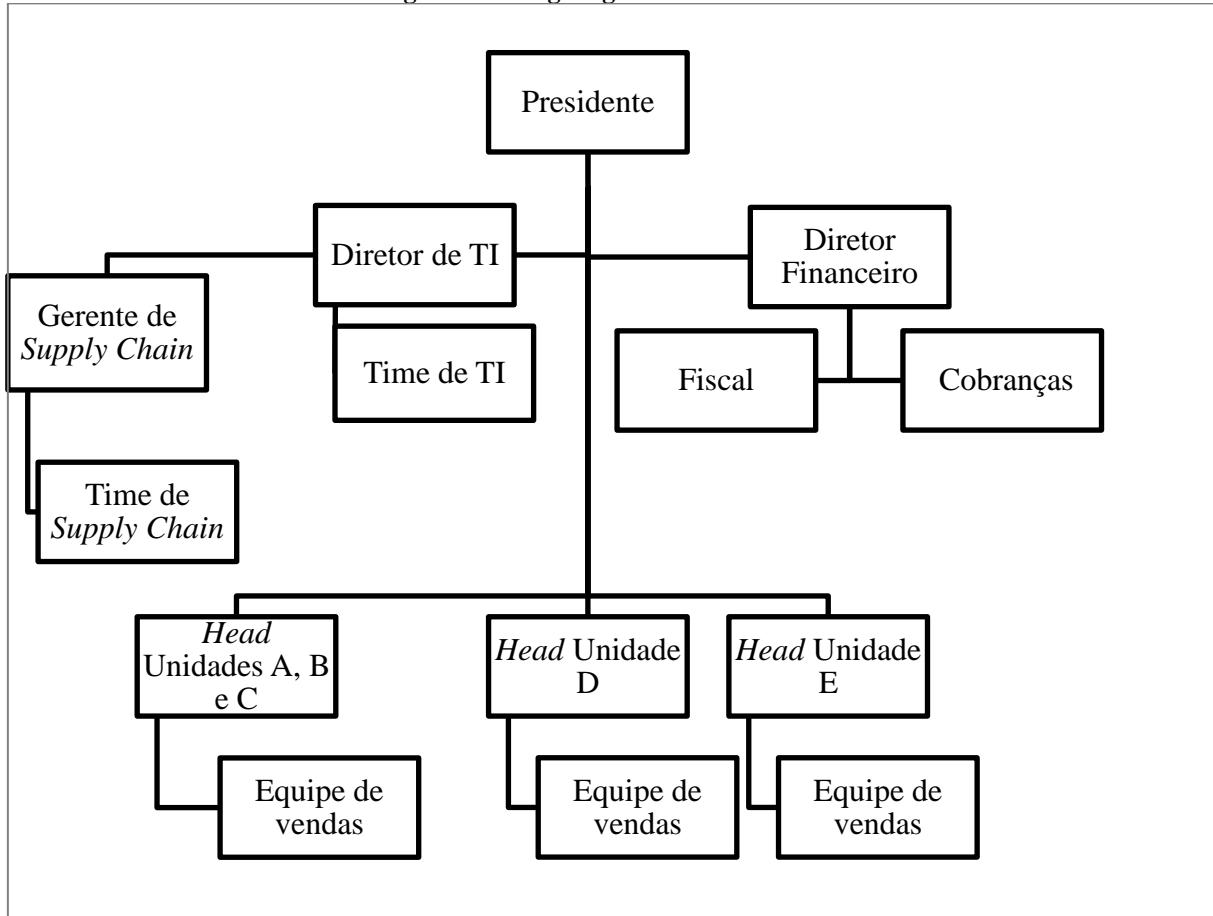
A VinhosCo iniciou suas operações na Argentina migrando para o Brasil logo após o seu surgimento, onde atua a mais de 15 anos importando e vendendo vinhos finos e derivados em cinco unidades de negócio diferentes. Neste trabalho, as unidades foram denominadas Unidade A, Unidade B, Unidade C, Unidade D e Unidade E.

As três primeiras unidades de negócio fornecem vinhos no varejo para consumidor final, as outras duas unidades fornecem para outros canais de distribuição que revendem para o consumidor final. Neste sentido, a empresa estuda a abertura de outra unidade de negócios, Unidade F, para atuar em um segmento extremamente concorrido que fornece vinhos para um terceiro tipo de intermediário de grande porte, representando uma grande oportunidade de alavancar as vendas.

1.2.1 Estrutura organizacional

A empresa conta atualmente com 170 funcionários divididos entre áreas de apoio e área comercial dentro das suas respectivas unidades de negócio. Para maior compreensão da estrutura organizacional, a Figura 1-1 apresenta o organograma da empresa VinhosCo.

Figura 1-1- Organograma da VinhosCo



Fonte: elaborado pelo autor com base em dados da empresa

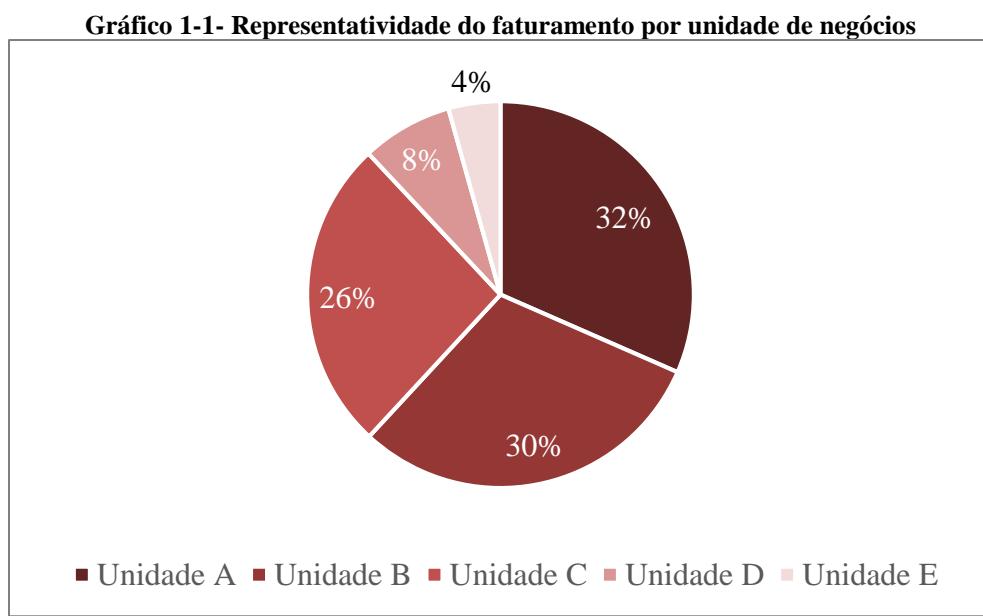
O diretor de Tecnologia de Informação (TI), o diretor financeiro e o gerente de *Supply Chain* respondem diretamente ao presidente da empresa fornecendo o apoio necessário para os *Heads* das Unidades A, B, C, D e E, os quais gerenciam as atividades comerciais.

A área de *Supply Chain* é enxuta, tendo apenas três funcionários sem formação específica neste âmbito. A área é responsável pela gestão do estoque, relacionamento com fornecedores, compras, distribuição, armazenagem e previsão de demanda. Nenhum funcionário apresenta conhecimentos sobre previsão de demanda, métodos quantitativos ou *softwares* comumente utilizados em empresas maiores.

Durante o desenvolvimento do trabalho, apesar da importância do tema, a alta gerência da empresa sinalizou que não pretendia investir na profissionalização da área ou na contratação de *softwares* para análises de previsão de demanda devido à reestruturação e ao corte de custos que estava sendo implementado na empresa.

1.2.2 Análise de faturamento da empresa e dados de mercado

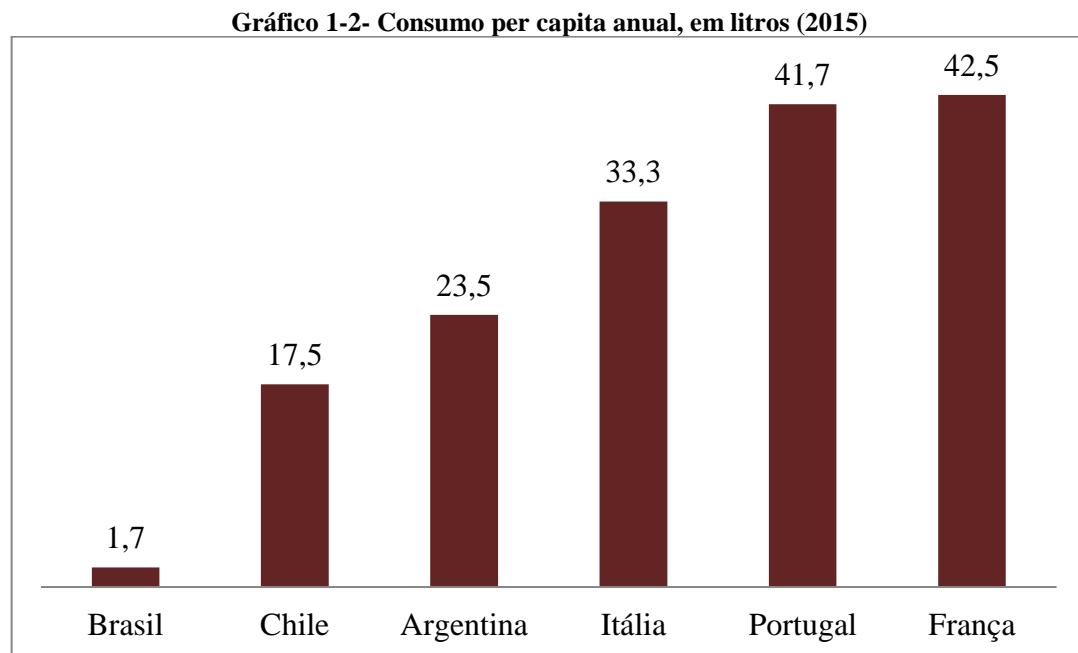
Como foi exposto anteriormente, a empresa possui cinco unidades distintas de negócio. O Gráfico 1-1 apresenta a representatividade do faturamento das unidades para dimensionar a importância de cada uma delas dentro do modelo de negócios da empresa.



Fonte: elaborado pelo autor com base em dados da empresa

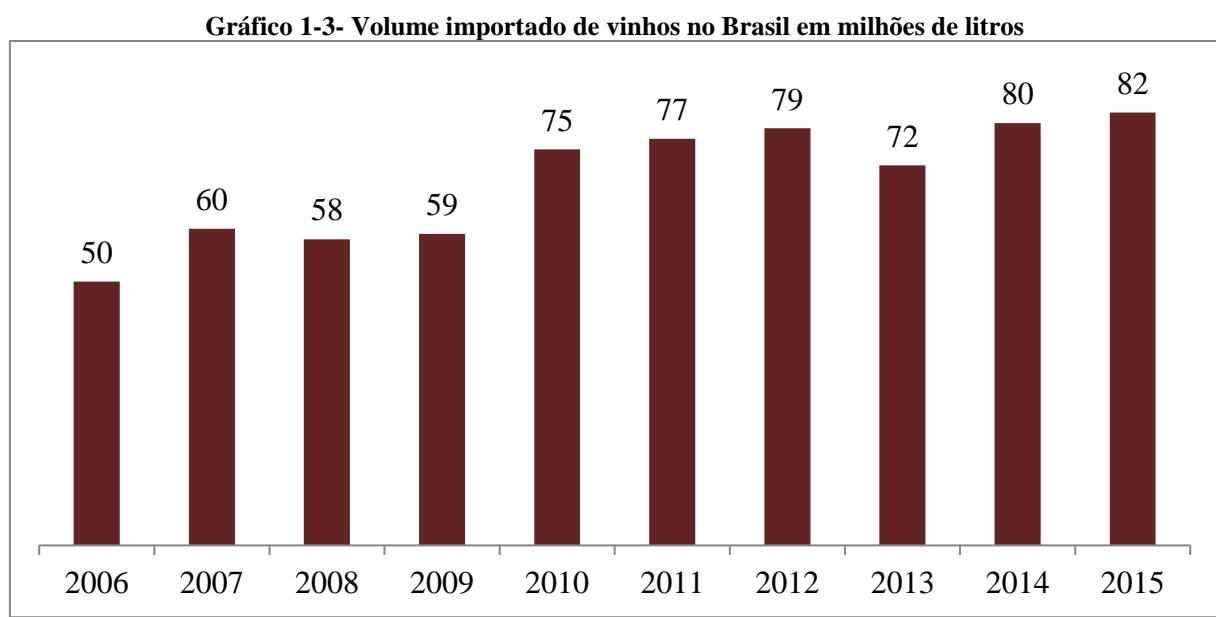
A empresa vem apresentando um forte crescimento nos últimos anos devido às oportunidades que o setor oferece. A melhora recente na distribuição de renda aumentou a percepção de qualidade do consumidor e seu poder de compra, fazendo com que o vinho fosse incorporado à mesa do consumidor. Mesmo com a atual recessão, o consumo de vinhos finos no Brasil aumentou 4,6% chegando a 9,1 milhões de litros (IBRAVIN,2016). Ainda há espaço

para muito crescimento, dado que o consumo de vinhos por parte dos brasileiros é muito abaixo da média de outros países como mostra o Gráfico 1-2.



Fonte: elaborado pelo autor a partir de dados do Ibravin (2016)

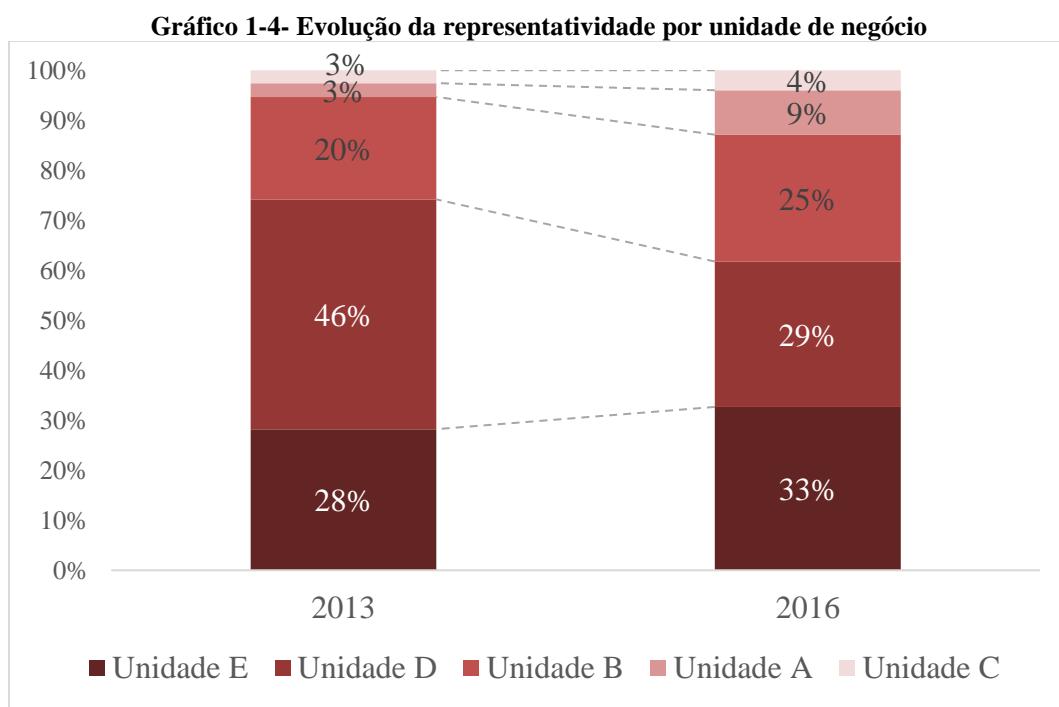
No Brasil são consumidos 1,7 litros por habitante contra 42,5 litros consumidos na França. Este número fica ainda menor se forem considerados apenas os vinhos finos, com um consumo per capita de apenas 0,7 litros (IBRAVIN, 2016). Como mostra o Gráfico 1-3, o volume das importações está aumentando consideravelmente nos últimos anos, crescendo mais de 60% entre 2006 e 2015, mostrando uma perspectiva de crescimento para o setor.



Fonte: elaborado pelo autor a partir de dados do Ibravin (2016)

Além disso, o setor é extremamente ramificado, sem a presença de um grande *player* que domina as importações e enorme variedade de rótulos importados. O faturamento do setor chegou em R\$1,8 bilhões em 2013, apresentando um crescimento de 131% em sete anos (IBRAVIN, 2013).

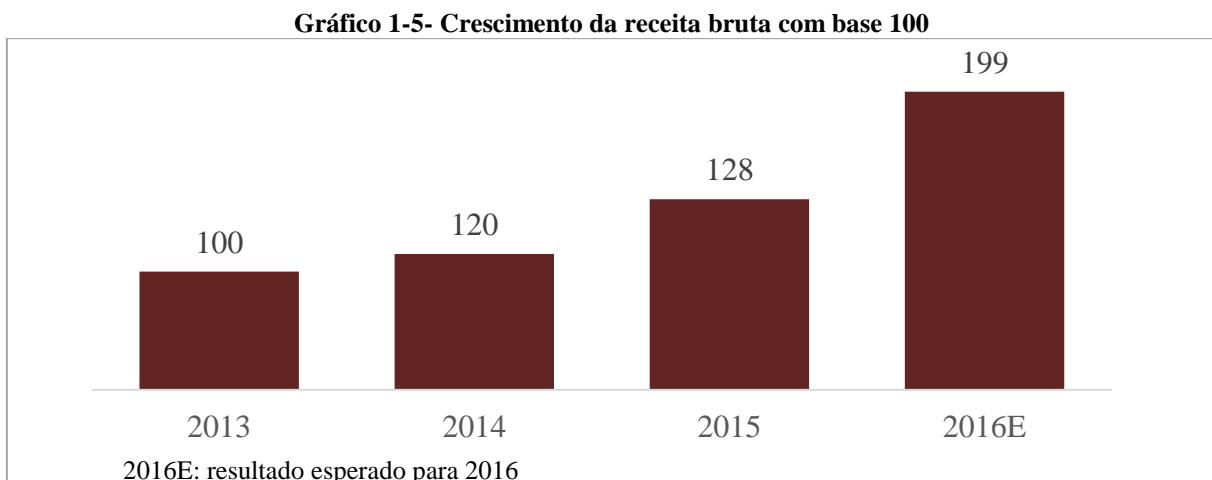
Dentro deste contexto, a Vinhos.Co adotou uma estratégia de modificar o foco comercial da empresa nos últimos anos, reestruturando a área comercial para dar ênfase em unidades que apresentam maior tendência de crescimento. A evolução da representatividade do faturamento das unidades de negócio da empresa é ilustrada no Gráfico 1-4.



Fonte: elaborado pelo autor com base em dados da empresa

Apesar da Unidade A ainda representar uma parcela pequena do faturamento, ela triplicou a sua representatividade nos últimos anos, sendo hoje, a grande aposta da companhia para o futuro. A Unidade D, em contrapartida, está enfrentando problemas devido às mudanças legislativas e tributárias, impactando profundamente o seu desempenho. Em consequência disso, a empresa está diminuindo sua exposição neste canal de forma progressiva.

Essa reformulação estratégica vem dando certo e os resultados mostram o forte crescimento. Esses dados são ainda mais significativos dado o cenário de crise econômica no país recentemente.



Fonte: elaborado pelo autor com base em dados da empresa

Como mostra o Gráfico 1-5, a empresa quase dobrou o seu faturamento entre 2013 e 2016 (2016 apresenta resultado esperado baseado no crescimento até outubro). Entretanto, algumas áreas não acompanharam este crescimento, entre elas, a área de *Supply chain*. É evidente que erros de previsão que não eram tão significativos anteriormente, agora apresentam um impacto importante na empresa. Impasses como estes podem prejudicar o plano de crescimento futuro da companhia, já que esta mantém a agressividade dos resultados passados com o objetivo de dobrar de tamanho nos próximos cinco anos¹.

1.3 Situação atual e problema a ser solucionado

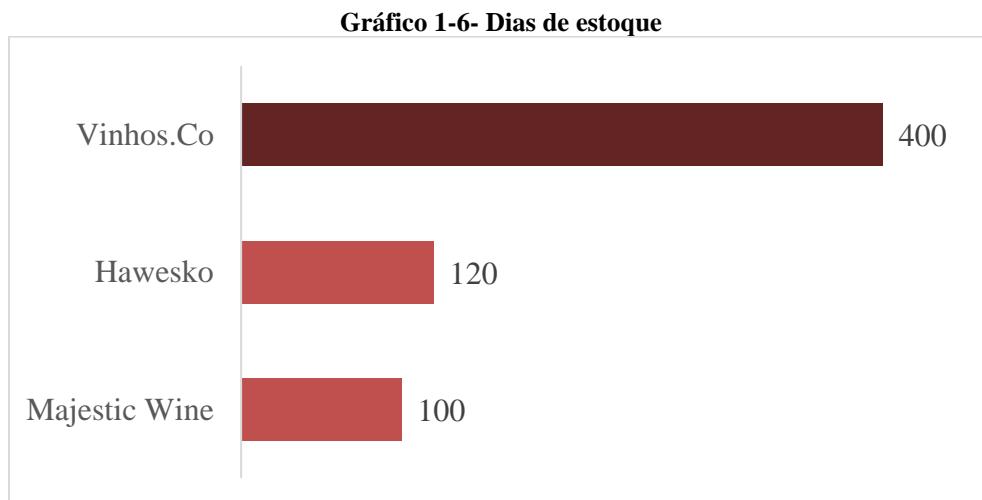
A empresa cresceu, até o momento, sem um método eficaz de previsão de demanda, o que tem se tornado um obstáculo estratégico tendo em vista o crescimento dos últimos anos. O atendimento à demanda e o custo de armazenagem são pontos cada vez mais importantes para o futuro da Vinhos.Co.

A quebra de estoque - falta de um produto que possui demanda - devido a um planejamento equivocado impacta principalmente as unidades de negócios que atendem *business to business*, unidades onde o produto passa por um intermediário antes de chegar ao consumidor final, devido à exigência que este tipo de cliente apresenta. Nestes casos, a quebra de estoque representa um risco maior já que, muitas vezes, existe a possibilidade de perder um cliente.

Como a empresa não possui métodos rigorosos de previsão de demanda, a solução encontrada foi possuir um patamar alto de inventário, que além de impactar o custo de

¹ Fonte: plano de longo prazo apresentado aos sócios

estocagem, não apresenta uma solução satisfatória dado que não dispõe de um *mix* ideal de estoque.



Fonte: elaborado pelo autor a partir de dados da Vinhos.Co e relatórios anuais das empresas

Como mostra o Gráfico 1-6, a Vinhos.Co apresenta níveis de estoque quatro vezes maiores do que a Majestic Wine[®], empresa de vinhos com origem no Reino Unido que possui mais de 200 lojas e 285 milhões de libras em faturamento em 2015²; e mais de três vezes o nível de estoque da Hawesco[®]; empresa de vinhos alemã com mais de 300 lojas e faturamento de 476 milhões de euros em 2015³. Observando companhias do mesmo setor que operam com excelência, fica evidente que a Vinhos.Co apresenta uma grande oportunidade de melhoria.

Outra consequência é o elevado custo de estocagem que 400 dias de estoque representam. Este valor alocado significa um custo de oportunidade desperdiçado já que a verba poderia ser direcionada para outras áreas ou ser investida, podendo resultar em crescimento ou vantagens competitivas.

O elevado número de SKUs que a empresa possui também é um fator complexo de ser administrado. Existem mais de 1500 SKUs divididos entre vinhos tintos, brancos, espumantes e outros. Além disso, os vinhos são distribuídos em diferentes faixas de preço, desde R\$30,00 podendo chegar a mais de R\$20.000,00.

² Fonte: retirado do relatório anual para investidores disponível no site: <http://majesticwineplc.co.uk/investor-centre/results-centre/>.

³ Fonte: retirado do relatório anual para investidores disponível no site: <https://www.hawesko.de/>.

Atualmente, a empresa utiliza como “modelo” de previsão de demanda uma planilha de Excel® com todos os 1500 SKUs na primeira coluna, seguido pela quantidade de garrafas vendidas nos últimos 60 dias, a quantidade de garrafas em estoque, o giro do estoque baseado nas duas variáveis anteriores e a quantidade recomendada que chegará nos meses seguintes, como ilustra a Tabela 1-1. Com esses dados, o gerente de *Supply Chain* analisa mensalmente a planilha, item por item, de maneira manual, até finalizar a lista e tomar decisões sobre futuras compras.

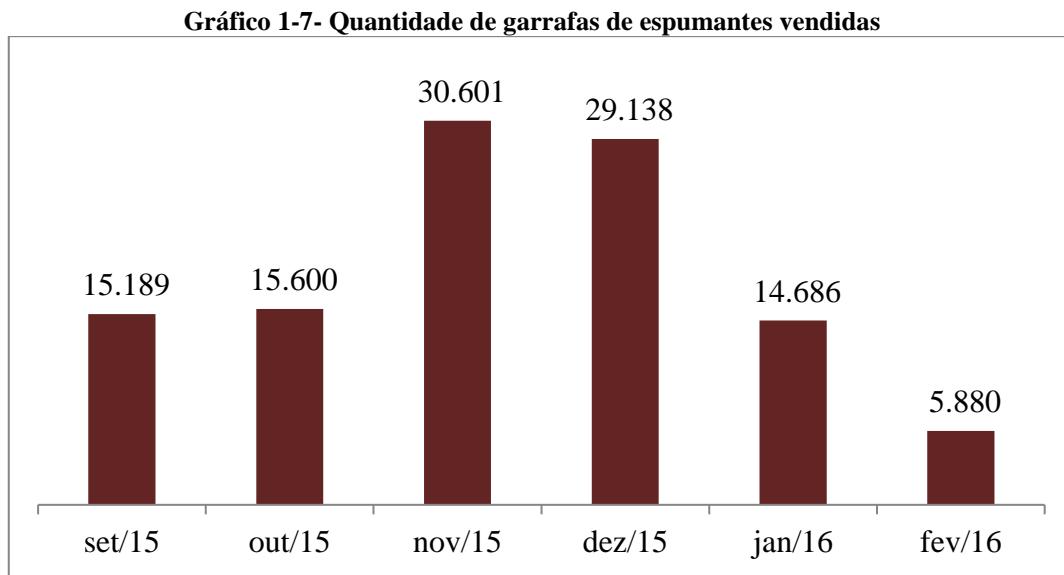
Tabela 1-1- Planilha de análise de estoque

SKU	vendas últimos 60 dias (garrafas)	Estoque (garrafas)	Giro (meses)	Compras (garrafas)
SKU 1	1.000	2.000	4	-
SKU 2	200	5.000	50	-
SKU 3	300	200	600	-
SKU 4	1.000	100	0	100
SKU 5	100	200	4	200
SKU 6	5	120	48	10

Fonte: elaborado pelo autor

Este tipo de abordagem proporciona diversos equívocos na análise dos dados e, portanto, nas tomadas de decisões subsequentes. Estas questões são elencadas a seguir:

- Processo manual: por se tratar de um processo totalmente manual e exaustivo, levando em média mais de quatro dias por mês para a elaboração da análise completa, e ser totalmente dependente dos olhos da gerente responsável, é propício a falhas pois facilita equívocos visuais como confundir linhas na planilha, não diagnosticar a necessidade de comprar determinado SKU ou fazer pedidos excessivamente grandes;
- Sazonalidade: a planilha não considera nenhum efeito sazonal nas vendas dos SKUs, o que gera problemas de grande impacto na empresa, como, por exemplo, a venda de espumantes que apresentam maior consumo nos períodos de festas.



Fonte: elaborado pelo autor com base em dados da empresa

Como podemos ver no Gráfico 1-7, no início de novembro, o gerente possuía os dados de vendas de setembro e outubro (30 mil garrafas vendidas), avaliando que o estoque seria suficiente para os próximos meses. No início de dezembro, a planilha de vendas passou a mostrar 45 mil garrafas vendidas nos dois meses anteriores, alertando a possibilidade de quebra no estoque em dezembro. No começo de janeiro, o número pulou dos 30 mil em novembro para 60 mil garrafas vendidas (sempre em relação aos dois meses anteriores), aqui ocorre uma falta de compreensão da situação atual, já que a planilha não mostra os 30 mil de vendas em novembro, neste ponto, a quebra é evidente e ninguém sabe responder como chegou nessa situação, e como medida corretiva, encomenda-se um grande número de garrafas de espumantes para os meses posteriores. Mas nos meses seguintes, as festas de fim de ano já passaram e a demanda por espumante cai drasticamente, o que gera um estoque superdimensionado para os meses seguintes, gerando assim, um novo problema. Apesar da empresa possuir dados de histórico de compras, estes não são utilizados, comprometendo a validade da previsão de demanda utilizada;

- *Lead Time:* Todos os produtos são importados da América do Sul e da Europa via frete marítimo, o que gera um *lead time* de aproximadamente 90 dias entre o pedido e o recebimento da mercadoria. Este prazo aumenta a importância de prever corretamente a demanda, dada a sua necessidade para a gestão do negócio;

- Dimensionamento de vinhos em diversas faixas de preços: a empresa possui um portfólio que busca atender os clientes em todas as faixas de preços, contemplado perfis variados de consumidores. O Gráfico 1-8 ilustra a dificuldade que produtos tão amplos apresentam, resultando em estoques superdimensionados para os produtos de faixas mais elevadas. Atualmente, a empresa possui mais de 40 anos de estoque para os SKUs que possuem preços superiores à R\$10.000,00.

Gráfico 1-8- Giro do estoque atual por faixa de preço em anos⁴



Fonte: elaborado pelo autor com base em dados da empresa

A parte qualitativa do processo atual surge durante a análise, sem nenhum controle ativo e de maneira informal. Quando um determinado SKU apresenta uma demanda muito alta, eventualmente pode ser apontado que este fez parte da promoção do mês anterior que deve, provavelmente, ter resultado no grande impacto nas vendas. Daí surgem dois problemas principais:

- Falta de histórico: Como a planilha apresenta apenas os últimos dois meses de vendas, não é possível comprovar se, de fato, a promoção foi responsável pela alta demanda do produto. Além disso, perde-se a informação de como as vendas do produto se deram nos meses anteriores, eliminando qualquer evidência de sazonalidade ou tendência;

⁴ Cálculo realizado com base nas vendas dos meses de abril a julho de 2016 e no estoque de julho do mesmo ano.

- Alta quantidade de SKUs: Com mais de 1500 SKUs é evidente que o processo de “lembra” se o produto foi impactado pelas promoções é totalmente suscetível à falha humana, resultando em análises e previsões distorcidas.

Sanar o problema de previsão de demanda da empresa é um requisito para a continuidade do projeto de expansão atual. A aplicação de métodos quantitativos de previsão de demanda na área de *Supply chain* da empresa é uma oportunidade de melhoria significativa, pois possibilita um planejamento mais eficaz e realocação de investimentos.

1.3.1 Motivação para desenvolver o tema

A empresa em questão era uma empresa familiar que foi comprada por um fundo de *Private Equity* por apresentar grande potencial de crescimento. O autor deste trabalho iniciou o estágio em um período em que a empresa apresentava forte crescimento de receita que a antiga estrutura da companhia não comportava.

O conhecimento adquirido ao longo do curso com disciplinas em que foram ensinados métodos quantitativos de previsão de demanda e a oportunidade de destaque que este desafio apresentou, tendo em vista o crescimento da empresa, o impacto da compreensão da demanda e suas consequências na Vinhos.Co, foram essenciais para motivar o desenvolvimento do tema do presente trabalho.

1.4 Objetivo do trabalho

Considerando os pontos apresentados anteriormente, o trabalho tem por objetivo prever a demanda por meio de métodos quantitativos apresentados na revisão da literatura.

O trabalho também apresenta o desafio de elaborar um modelo de fácil compreensão para os funcionários e que possa ser utilizado cotidianamente, permitindo o acompanhamento da demanda, a fim de fornecer informações estratégicas para a empresa.

Devido ao grande número de SKUs que a empresa possui, optou-se, no presente trabalho, pela previsão das principais famílias de produtos da Vinhos.Co, evitando, assim, um estudo excessivamente longo e repetitivo.

2 REVISÃO DA LITERATURA

Para embasamento teórico do presente trabalho, foi feita uma revisão da literatura, abordando os principais autores e referências em métodos de previsão de demanda, bem como análise de outros conceitos que se fizeram necessários para o desenvolvimento do trabalho.

2.1 Por que prever?

A partir dos anos 1960, houve um significativo aumento nos investimentos em processos de previsão dentro das empresas. Segundo Wheelwright e Makridakis (1985), isso se deve à cinco fatores principais: primeiro porque o ambiente organizacional foi se tornando cada vez mais complexo, dificultando o processo de tomada de decisão – ficava cada vez mais difícil ponderar todos os fatores sem um auxílio explícito e sistemático; em segundo lugar, as organizações cresceram muito de tamanho, aumentando também o impacto de cada decisão a ser tomada; terceiro ponto importante é que, além da complexidade dos ambientes organizacionais, estes também mudavam de configuração muito rapidamente – como as relações não eram mais estáveis, era necessária uma ferramenta que pudesse identificar e analisar rapidamente essas novas composições; além disso, muitas organizações estavam indo em direção à um processo de tomada de decisão mais sistemático, exigindo uma justificativa mais objetiva dessas ações; por fim, era interessante a ideia de que processos de previsão pudessem ser feitos por funcionários comuns e não apenas por especialistas - e a construção de um modelo de previsão permitiria isso.

Segundo Bails e Peppers (1976), o primeiro objetivo da construção de um modelo de previsão é melhorar o processo de tomada de decisão através da organização e análise dos dados existentes, o que auxilia na diminuição da incerteza. Em segundo lugar, o modelo deve ser capaz de simular as consequências de aleatoriedades e quantificar os efeitos de soluções alternativas. Dessa forma, os autores sugerem que os dados envolvidos com o problema devem ser analisados minuciosamente, de modo a produzir um embasamento aos profissionais responsáveis pela tomada de decisão dentro de uma empresa.

Para Makridakis (1998), o processo de previsão, e principalmente, o processo de previsão de demanda, é uma parte importante para o processo de tomada de decisão gerencial. Para estabelecer metas e objetivos que sejam possíveis de serem alcançados, é necessário que ocorra um exercício de prever os fatores ambientais que vão impactar o resultado esperado ao longo do tempo. Como as áreas de uma empresa são cada vez mais interligadas, erros em determinada

área podem gerar um impacto em toda a companhia, resultando em um desempenho abaixo do esperado. As áreas em que o autor determina que a previsão de demanda gera maior impacto são:

- Agendamento: organização da produção, transporte e serviços essenciais à empresa;
- Aquisição de recursos: *lead time* para a aquisição de recursos-chave para a empresa pode variar de dias a anos;
- Determinação de recursos futuros: organização de recursos que se pretende ter no futuro.

Na área de agendamento, é essencial que a produção, o transporte e os serviços estejam condizentes com as necessidades da empresa, atentando-se, principalmente, aos prazos. Em relação à aquisição de recursos, o *lead time* da entrega de produtos chave para a empresa deve ser calculado, alinhando-se com a demanda de cada produto. Sendo assim, é importante que o planejamento das compras seja eficaz; caso contrário pode-se enfrentar diversos problemas, como a quebra de estoque. A última área que Makridakis (1998) enfatiza é a de determinação de recursos futuros, na qual a organização deve planejar quais recursos que se pretende ter no futuro, tendo como base as oportunidades de mercado, o desenvolvimento da empresa, os objetivos a serem atingidos e os recursos humanos disponíveis.

Dessa forma, o aumento da complexidade das empresas promoveu uma ligação maior entre as áreas, gerando uma interdependência. Erros na previsão de demanda podem ocasionar diversos problemas, tais como aumento no inventário, impacto no fluxo de caixa da empresa e no marketing e dificultar o alcance de metas pré-estabelecidas. Pode-se ver, portanto, que prever é um processo essencial e extremamente delicado: a previsão, se não feita com acurácia, pode gerar impasses ainda maiores (ROTHE, 1978).

2.2 Prever e planejar

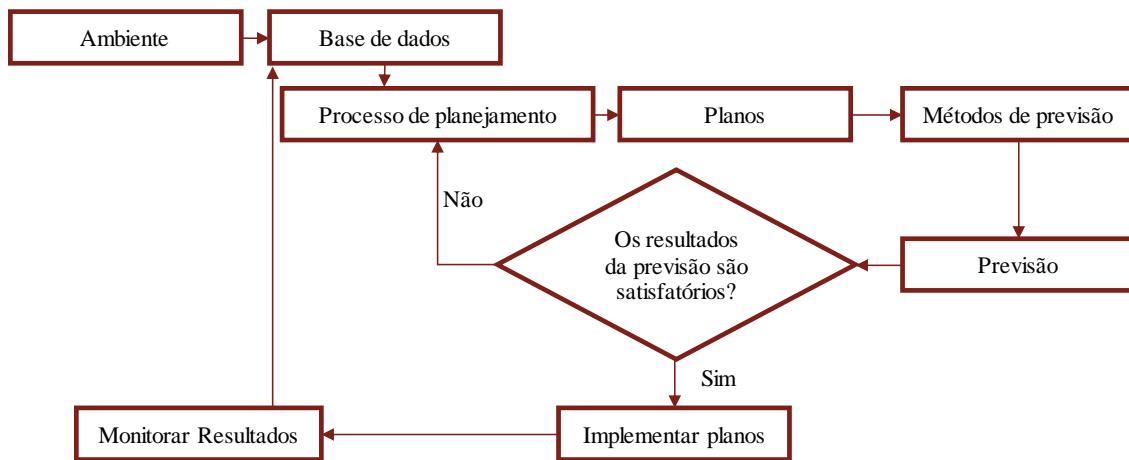
Segundo Armstrong (2001), modelos de previsão são ainda mais necessários quando não há precisão sobre o futuro ou quando há a necessidade de diminuir as consequências provenientes dessa incerteza. Muitas vezes, dentro de uma empresa, os modelos de previsão que viriam para ajudar nesses momentos são confundidos com os planos da companhia.

Enquanto este diz respeito a como o mundo deveria se parecer, um modelo de previsão de demanda indica como o mundo se parecerá. Esta definição de espaços pode ser significativa para a implementação de um modelo que seja, verdadeiramente, de previsão.

Segundo o autor, os responsáveis pelos planos da empresa devem usar modelos de previsão, desde que estes sejam satisfatórios, para mudar os planos de acordo com a previsão. Apesar de parecer óbvio, o que muitas vezes acontece é o processo inverso, ou seja, as empresas mudam os modelos de previsão para se ajustarem a seus planos. A Figura 2-1 apresenta um *framework* sobre previsão e planejamento, que ajuda a ilustrar o papel de cada uma dessas etapas e como se relacionam.

A Figura 2-1 apresenta um *framework* sobre previsão e planejamento.

Figura 2-1- Framework para prever e planejar



Fonte: adaptado de Armstrong (2001)

O primeiro passo é transformar os acontecimentos que impactam na previsão em dados para que ocorra o processo de planejamento, que consiste em decidir antecipadamente o que fazer, como fazer, quando fazer, onde fazer, quanto fazer e quem fazer⁵. Após a elaboração dos planos, aplica-se os métodos de previsão existentes para, então, prever. Neste ponto, ocorre a análise dos resultados: caso os resultados de previsão apresentem erros dentro do esperado, implementa-se o método de previsão com a monitoração dos resultados; por outro lado, se estiverem fora do erro aceitável, deve-se retornar para o processo de planejamento.

⁵ Retirado de aulas ministradas pelo Prof. Dr. Álvaro Euzébio Hernandez.

A fase de monitoramento de dados inclui a constante alimentação da base de dados com as últimas atualizações do ambiente. Isso significa que o processo é iterativo já que uma vez alimentada a base de dados, os resultados podem apresentar variações acima do aceitável, o que resulta em um novo planejamento e assim sucessivamente.

2.3 Passos básicos para previsão

Bails e Peppers (1982) definem que a previsão é um resultado de um processo evolutivo: primeiro, deve-se identificar o problema a ser resolvido; segundo, deve-se obter os dados necessários; terceiro, deve-se definir o melhor método de previsão e por fim, os resultados devem ser interpretados e integrados ao processo de tomada de decisão.

Makridakis (1998) retoma essa divisão, aprimorando-a:

1. Definição do problema

Muitas vezes a definição do problema é um dos aspectos mais difíceis de um modelo de previsão. É necessário entender a fundo como o modelo de previsão será utilizado, quem o solicitou e como suas funções impactarão a organização. É essencial conversar com todos os envolvidos na coleta de dados, manutenção das bases, e usuários do modelo que tomarão decisões futuras e estratégicas para conhecer quais produtos são armazenados, qual o nível de demanda que a empresa está preparada para suportar, quanto tempo demora para se obter cada item, e assim por diante.

2. Coleta de informações

Existem dois tipos de informações necessárias para a previsão: informações estatísticas e dados e as que se referem ao conhecimento e experiências acumuladas de pessoas-chave dentro da organização. É necessário que se tenha dados históricos da demanda para alimentar o modelo e fomentar análises.

3. Análises preliminares

Para ter uma compreensão inicial da primeira mensagem que os dados transmitem, normalmente gera-se gráficos para inspeções visuais que podem, por exemplo, dizer sobre possíveis métodos de previsão a serem utilizados.

4. Escolha e montagem de modelos

Neste passo, escolhe-se o modelo que melhor representa a série. Cada modelo é, por si só, um constructo individual baseado em uma série de premissas envolvendo parâmetros baseados no histórico dos dados.

5. Usar e avaliar o modelo de previsão

Uma vez escolhido um modelo de previsão e estimados os seus parâmetros, o modelo deve ser utilizado para realizar as previsões, gerando análises positivas ou negativas de sua utilização ao longo do tempo. Um modelo de previsão só pode ser avaliado após sua utilização, para que haja uma comparação com os dados reais que este se dispôs a prever.

Além dos pontos citados, Diebold (1998) define seis tópicos relevantes para que um modelo de previsão de demanda possa ser considerado bem-sucedido:

1. Decisões do ambiente

Para escolher o melhor modelo é necessário avaliar quais as decisões que o modelo de previsão pretende resolver. Além disso, deve-se entender as características que definem sua qualidade, bem como avaliar o custo associado às perdas devidos aos erros e customizar cada modelo segundo diferentes situações.

2. Objetivo da previsão

Como Makridakis et al. (1998), Diebold (1998) considera a definição do objetivo do modelo extremamente importante para que se alcance o sucesso. O autor também pontua questões como qualidade e quantidade de dados, tipos de séries e diferentes tipos de objetivos. Todos esses pontos têm papel crucial no resultado final da construção de um modelo.

3. Definição da previsão

É necessário definir o que e como se deseja prever. Uma previsão pode gerar um resultado específico ou uma faixa de resultados que não geram danos futuros. A escolha dentre essas características leva em conta o produto em questão e é essencial para definição do modelo.

4. Horizonte de previsão

Para definir o horizonte da previsão é necessário que se estabeleça as especificidades do produto em que se busca a previsão de demanda. Para alguns produtos o ideal é que a previsão

seja feita para um mês a frente e para outros um ano a frente: as características do produto e da empresa são definidoras do melhor horizonte de previsão.

Segundo Bails e Pepper (1982), os horizontes de previsão podem ser definidos em:

- a) curtíssimo prazo: menos de um mês;
- b) curto prazo: um a seis meses;
- c) médio prazo: seis meses a dois anos;
- d) longo prazo: mais de dois anos.

5. Conjunto de informações

É importante avaliar em quais dados essa previsão se baseará: dados antigos e dados próximos tem suas especificidades e podem levar a resultados diferentes. A escolha de um modelo precisa ser alinhada com o banco de dados que se tem como suporte.

6. Métodos e complexidade

Para diferentes problemas, podem ser necessários métodos distintos. A variedade dos métodos permite satisfazer diversos tipos de problemas. Para alguns dados, métodos mais simples são necessários, enquanto que, para outros, é necessária a utilização de métodos mais complexos. Cada um deles apresenta sua acurácia, e para determinar o melhor é necessário saber medi-la.

2.4 Acurácia

Qualquer tentativa de previsão está sujeita à diversos tipos de erros que podem distorcer os dados de maneira significativa. Dessa forma, para avaliar os erros e discrepâncias de modelos é essencial medir a acurácia, que é o grau de proximidade de uma estimativa com seu valor verdadeiro (MIKHAIL e ACKERMANN, 1976).

2.4.1 Erros de previsão

A acurácia do modelo em prever a demanda futura é um dos pontos mais importantes para seus usuários. Assim, define-se o erro no instante t (e_t):

$$e_t = Y_t - F_t$$

Onde Y_t = valor real observado no instante t

F_t = valor previsto no instante t

Esta equação descreve o erro de um período à frente, sendo e_t o erro de uma única observação. Para se definir uma variável com n períodos observados e, por consequência, n erros, tem-se as seguintes equações:

Erro Médio (ME ou *mean error*)

$$ME = \frac{1}{n} \sum_{t=1}^n e_t$$

Onde n = número de períodos observados

O ME pode ter erros positivos anulados por erros negativos, por isso não serve como indicador do tamanho do erro cometido e sim para evidenciar se está ocorrendo um erro de forma sistemática para cima ou para baixo, conhecido como viés de previsão.

Erro médio absoluto (MAE ou *mean absolute error*)

$$MAE = \frac{1}{n} \sum_{t=1}^n |e_t|$$

Neste caso, soma-se os módulos dos valores dos erros para o cálculo da média. Desta forma, evita-se a anulação dos erros como no caso do ME.

Erro quadrático médio (MSE ou *mean squared error*)

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

Tem efeito similar ao MAE pois torna cada erro positivo com o uso da potência utilizada na equação, além de possuir a vantagem de ser mais fácil de explicar para não especialistas e ser mais prático para utilização matemática.

Todas essas medidas de erros são dependentes da escala de dados utilizadas e dos intervalos de tempo: erros na previsão diária não são comparáveis a erros na previsão anual, por exemplo. Para torná-los comparáveis, é necessário trabalhar com medidas relativas de erros (em forma de porcentagem), como mostrado a seguir:

Erro percentual (PE ou *percentage error*)

$$PE_t = \left(\frac{Y_t - F_t}{Y_t} \right) * 100$$

Erro percentual médio (MPE ou *mean percentage error*)

$$MPE = \frac{1}{n} \sum_{t=1}^n PE_t$$

Erro percentual médio absoluto (MAPE ou *mean absolute percentage error*)

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t|$$

2.5 Métodos qualitativos

De acordo com Ballou (2001), os métodos qualitativos são aqueles que usam o julgamento, a intuição, as pesquisas ou as técnicas comparativas para produzir estimativas qualitativas a respeito do futuro. A informação relacionada aos fatores que afetam a previsão é tipicamente não-quantitativa e subjetiva. Os dados históricos podem não estar disponíveis ou podem ser pouco relevantes para a previsão. A natureza não científica dos métodos torna-os difíceis de padronizar a validar em termos de acurácia.

São comumente adotados quando existe pouca ou nenhuma informação disponível mas existe conhecimento qualitativo suficiente. Dessa forma, esses métodos podem ser os únicos disponíveis ao tentar prever o sucesso de produtos novos, mudanças na política do governo ou impacto de uma nova tecnologia, sendo mais utilizados, portanto, para previsões de médio para longo alcance.

Diferente do método quantitativo, métodos qualitativos podem apresentar variações bruscas em relação à custo, complexidade e valor. Muitas vezes os dois métodos são aplicados

simultaneamente com o intuito de fornecer informações preciosas para os tomadores de decisão dentro das companhias em áreas como desenvolvimento de novos produtos, dispêndios de capital, formulação de metas e fusões e aquisições (MAKRIDAKIS,1998).

2.6 Séries temporais

Séries temporais são dados observados ao longo do tempo; podem ser, por exemplo, a quantidade vendida de determinado produto por mês ou volume de chuva que cai por ano em uma determinada região.

Para aplicação de métodos quantitativos em séries temporais, é necessário considerar que os dados são igualmente distribuídos ao longo do tempo. Essa simplificação não surge como uma restrição ao método pois a maioria dos dados fornecidos já são distribuídos ao longo do tempo, como por mês, trimestre, semestre ou ano (MAKRIDAKIS,1998).

Makridakis (1998) acrescenta que, além dessa simplificação, três condições devem existir para que seja possível aplicar métodos quantitativos:

- Informação sobre o passado deve estar disponível;
- Essa informação pode ser quantificada em dados numéricos;
- É possível assumir que algumas características do passado irão se repetir no futuro.

A última premissa é conhecida como premissa da continuidade e é também encontrada em diversos modelos, até mesmo nos modelos quantitativos mais complexos.

2.6.1 Visualização gráfica

Um dos passos mais importantes quando se começa a examinar uma série temporal é colocá-la em forma de gráfico. Desta forma fica mais fácil perceber características da série, além de possibilitar explicações para variações de dados.

Os diferentes tipos de dados determinam qual o tipo de gráfico mais apropriado para visualização. Três tipos distintos de gráficos são mais comumente utilizados.

- Gráfico temporal: mostra o comportamento da série ao longo do tempo, que se encontra no eixo x. Com essa visualização, fica fácil perceber características das

séries como sazonalidade, tendências entre outras. Essas características devem ser incorporadas ao modelo matemático para que se obtenha maior acurácia na previsão;

- Gráfico sazonal: mostra a sazonalidade da série. Para montá-lo, se fixa no eixo x o período de sazonalidade e se distribui as diferentes safras ao longo deste período. Por exemplo, um produto com sazonalidade anual apresentará no eixo x os meses de janeiro a dezembro, sem o ano, e no eixo y dados de diferentes anos;
- Gráfico de dispersão: utilizado normalmente para mostrar como uma variável impacta outra; é mais comum em séries atemporais.

2.6.2 Principais séries temporais

Existem quatro principais tipos de séries temporais:

- Horizontal: este padrão é percebido quando os dados flutuam ao redor de uma média constante; uma série onde não ocorre decréscimo ou acréscimo, também conhecida como série estacionária;
- Sazonal: ocorre quando a série é influenciada por fatores sazonais, como produções agrícolas que dependem de períodos de colheitas e secas. São chamadas muitas vezes de séries periódicas apesar de, não necessariamente, se repetirem ao longo do tempo;
- Cíclica: existe quando os dados exibem altas e quedas que não estão em um período fixo. Muito utilizada para explicar flutuações econômicas que estão associadas à ciclos de negócios. A maior diferença entre uma série sazonal e uma série cíclica é que enquanto a sazonal se repete ao redor de um comprimento fixo, a cíclica ocorre em um comprimento variável. As grandes crises econômicas, por exemplo, são cíclicas pois não ocorrem a cada 20 anos, mas se repetem em ciclos que podem durar mais ou menos;

- Tendência: ocorre quando existe um acréscimo ou decréscimo de longo termo na série.

2.6.3 Transformações e ajustes

Em alguns casos é necessário realizar um pequeno ajuste nos dados para tornar a informação mais interpretativa e segura. A seguir será apresentado três tipos de ajustes que visam melhorar a acurácia da previsão.

- Transformação matemática: utilizado para simplificar séries que apresentam padrões não uniformes ao longo do tempo. A transformação matemática visa facilitar a análise estandardizando esses padrões por meio de mudanças de variáveis e transformações gráficas;
- Ajuste de calendário: utilizado para garantir que os períodos avaliados possuam exatamente o mesmo comprimento. Um mês com 28 dias não apresenta o mesmo comprimento que um mês com 31 dias, podendo gerar um erro de até 10%. Esta falha é facilmente corrigida pela equação a seguir:

$$W_t = Y_t * \frac{\text{número médio de dias no mês}}{\text{número de dias no mês } t}$$

Onde W_t = valor corrigido no instante t

Y_t = valor original no instante t

- Ajuste de comércio: similar ao ajuste anterior, mas é relacionado a dados financeiros, como corrigir uma série de evolução de receita pela inflação do período, para que a tendência possa ser vista pela mesma base.

2.6.4 Princípio de decomposição

Métodos de decomposição são utilizados para identificar padrões que caracterizam a série, que podem ser padrões sazonais e de tendências.

A decomposição assume que os dados respeitam as seguintes equações:

$$\text{Dado} = \text{padrão} + \text{erro}$$

$$\text{Dado} = f(\text{tendência} - \text{ciclicidade}, \text{sazonalidade}, \text{erro})$$

Existem diversas maneiras de isolar cada componente da equação de modo a atingir a maior acurácia possível. O método básico isola primeiramente o componente de tendência-ciclicidade para em seguida isolar o componente de sazonalidade, considerando componentes residuais como efeitos de aleatoriedade, dado que não podem ser previstos nem identificados (MAKRIDAKIS,1998).

A representação geral da abordagem matemática de decomposição é:

$$Y_t = f(S_t, T_t, E_t)$$

Onde Y_t = valor real observado no instante t

S_t = componente de sazonalidade no instante t

T_t = componente de tendência no instante t

E_t = componente de aleatoriedade no instante t

O método de decomposição determina a forma da função exata. Existem duas abordagens principais:

Decomposição aditiva

$$Y_t = S_t + T_t + E_t$$

Considera que os componentes sazonais, tendência-ciclicidade e irregulares são simplesmente adicionados para que se chegue ao valor observado da série.

O método de decomposição aditiva é aconselhado em casos onde a magnitude das flutuações sazonais não variam com o nível da série.

Decomposição multiplicativa

$$Y_t = S_t \times T_t \times E_t$$

Considera que os componentes sazonais, tendência-ciclicidade e irregulares sejam multiplicados para que se chegue ao valor observado da série.

Segundo Ballou (2001), a decomposição multiplicativa é utilizada justamente em casos onde a decomposição aditiva falha, ou seja, em séries onde as flutuações sazonais variam proporcionalmente com o nível da série.

Para ilustrar a decomposição multiplicativa, será apresentado a seguir um exemplo de transformação muito utilizado: a transformação logarítmica.

$$Y_t = S_t \times T_t \times E_t$$

$$\log Y_t = \log S_t + \log T_t + \log E_t$$

Este tipo de transformação pode transformar facilmente uma relação multiplicativa em uma relação aditiva. Outras transformações podem apresentar diferentes decomposições.

2.6.5 Métodos de previsões para séries temporais

Os modelos causais para a previsão de demanda são construídos sobre a premissa básica de que o nível de variação de previsão origina-se do nível de outras variáveis relacionadas (BALLOU,2001).

Segundo Ballou (2001) e Wheelwright e Makridakis (1985), diversos estudos mostram que o aumento da complexidade e da sofisticação estatística do modelo não significa necessariamente a melhora da acurácia dos modelos de previsão - modelos considerados mais “simples”, frequentemente preveem tão bem, ou melhor, do que versões mais sofisticadas e complexas. Esses dados são muito importantes uma vez que aumenta o uso potencial de modelos de previsão, dado que a simplicidade é uma característica positiva.

A seguir serão apresentados os principais métodos para previsão de demanda, evidenciando suas características e complexidades.

Métodos de Média

Média Simples (MS)

Consiste em considerar a média de todos os dados observados para fazer a previsão.

$$F_{t+1} = \frac{1}{t} \sum_{i=1}^t Y_i$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

F_t = valor previsto para o instante t

Este método é indicado apenas para séries estacionárias que não apresentam tendências nem sazonalidade.

Média Móvel (MM)

Cada ponto de uma média móvel de uma série de tempo é a média aritmética ou ponderada de um número de pontos consecutivos das séries, no qual o número de pontos de dados é escolhido de modo que os efeitos de sazonalidade ou as irregularidades ou ambos sejam eliminados. É considerado um método simples para suavizar o histórico dos dados e indicado para previsões de curto prazo.

Um dos desafios para este método é definir a quantidade de períodos a serem considerados na média. Quantidades menores de períodos dão mais peso aos valores mais recentes, tornando o modelo mais sensível a recentes variações.

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

k = ordem da média móvel, ou seja, número de períodos considerados

Algumas considerações sobre o método são:

- Leva em consideração apenas os últimos k períodos observados;
- A quantidade de dados considerados em cada média é constante ao longo do tempo;
- Requer maior histórico porque todos as k observações devem ser armazenadas, não apenas as médias;
- Apresenta limitações para lidar com tendências e sazonalidades.

Suavização Exponencial Simples (SES)

Diferente do método da média móvel, que atribui o mesmo peso para cada observação, a SES atribui um peso exponencial ao longo da série atribuindo maior peso aos dados mais recentes por considerá-los melhores guias para os números futuros.

$$F_{t+1} = \alpha Y_t + (1 - \alpha)^2 Y_{t-1} + (1 - \alpha)^3 Y_{t-2} + \dots + (1 - \alpha)^t Y_1$$

$$F_{t+1} = F_t + \alpha (Y_t - F_t)$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

F_t = previsão de demanda no instante t

α = constante entre zero e um

Assim que o valor observado é conhecido, obtém-se o erro no período t dado por $(Y_t - F_t)$ e ajusta-se a previsão para o período t+1. Ou seja, a previsão atual é igual à antiga previsão acrescida de um ajuste.

Ao ajuste, é atribuído um peso α que deve minimizar o MAPE. Valores de α próximos de zero significam que o erro observado irá resultar em um pequeno ajuste.

Apresenta a vantagem de não ser necessário armazenar um grande número de dados já que apenas com um histórico das observações e previsões mais recentes junto com o valor de α são suficientes para a realização do método.

Método de Suavização Exponencial com Tendência/ Linear de Holt

Este método é uma extensão do método anterior com uma adaptação que permite prever com maior acurácia séries com tendência.

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

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$F_{t+m} = L_t + b_t m$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

L_t = nível de série no período t

b_t = tendência da série no período t

F_t = previsão de demanda no instante t

m = número de períodos a frente que deseja prever

α = constante de ponderação exponencial para a base (entre 0 e 1)

β = constante de ponderação para a tendência (entre 0 e 1)

L_t é ajustado diretamente pela tendência do período anterior, b_{t-1} , adicionando o último valor de L_{t-1} . Com isso, o atraso é diminuído, trazendo L_t para um valor mais preciso. b_t atualiza a tendência que deve sofrer alta ou queda em relação ao valor anterior.

O β elimina qualquer aleatoriedade que ficou remanescente na série. Como no método anterior, o desafio é encontrar os valores de α e β que minimizam o MAPE da série.

Método de Suavização Exponencial com Sazonalidade

É semelhante ao método anterior, com o diferencial de que, ao invés de tratar a tendência da série histórica, este método leva em consideração a sazonalidade. Possui duas constantes de suavização, α e β , para a base e para a sazonalidade, respectivamente.

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

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

$$F_{t+m} = L_t \times S_{t-s+m}$$

Onde s = comprimento da sazonalidade

S_t = sazonalidade no instante t

L_t = nível de série no período t

γ = constante de ponderação para a sazonalidade

Método Holt-Winters de Suavização Exponencial com Tendência e Sazonalidade

Os métodos anteriores são falhos quando a série apresenta sazonalidade, podendo apresentar erros por não possuírem equações que prevejam essa variável. Neste sentido, o

método de Holt-Winters trabalha com três equações diferentes: equação de nível, equação de tendência e equação de sazonalidade.

Existem dois métodos distintos de Holt-Winters que dependem de como a sazonalidade foi modelada.

Multiplicativo:

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

Tendência:
$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

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

Previsão:
$$F_{t+m} = (L_t + b_t m)S_{t-s+m}$$

Onde s = comprimento da sazonalidade

Aditivo

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

Tendência:
$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

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

Previsão:
$$F_{t+m} = L_t + b_t m + S_{t-s+m}$$

A diferença entre o método aditivo e multiplicativo é que os índices de sazonalidade são somados e subtraídos naquele. O método aditivo é menos comum de ser encontrado em modelos.

Como nos métodos anteriores, o desafio é encontrar α , β e γ que minimizem o MAPE.

2.7 Métodos causais

Métodos causais se baseiam na premissa de que o nível da variação da previsão origina-se do nível de outras variáveis relacionadas, resultando em boas antecipações em mudanças em períodos de médio e longo alcance.

O maior problema com essa classe de modelo de previsão é que as variáveis verdadeiramente causais são difíceis de encontrar. Quando são encontradas, sua associação com a variável a ser prevista é, com frequência, perturbadoramente baixa. As variáveis causais que conduzem a variável prevista no tempo são até mesmo mais difíceis de serem encontradas. Demora de um a seis meses para serem adquiridos dados para a variável principal. Os modelos baseados na regressão e em técnicas econômicas podem apresentar erro substancial de previsão por causa desses problemas (BALLOU,2001).

A seguir serão apresentadas algumas formas de modelos causais.

Estatísticos

- Modelo de regressão:

Relaciona a demanda com suas causas selecionando variáveis no campo da significância estatística. São populares devido a disponibilidade de programas de regressões e são comumente utilizados para prever um horizonte de curto-médio prazo;

- Modelo econométrico:

Utiliza de um sistema de equações interdependentes de regressão que descreve algum setor de atividade econômica. Em geral, estimam os parâmetros de maneira simultânea e apresenta alto custo de implementação. Apresentam maior acurácia por conseguir explicar melhor as causalidades devido à utilização de equações inerentes e são melhores empregados para horizontes de curto-médio prazo.

Descritivos

- Modelo de entrada e saída:

Preocupa-se com o fluxo de produtos ou serviços interdepartamentais. Para que ocorram determinadas saídas, devem ocorrer fluxos de entrada. Exige um esforço considerável para utilizar esse modelo que possui um horizonte de previsão de médio prazo;

- Análise do ciclo de vida:

Análise e previsão do crescimento do novo produto baseado em curvas S. As fases de aceitação do produto por vários grupos como os inovadores, maioria adiantada, maioria atrasada, e os retardatários são centrais à análise.

3 PREVISÃO DE DEMANDA DA VINHOS.CO

Com base na revisão da literatura realizada e considerando o problema enfrentado pela Vinhos.Co, este capítulo tem por objetivo apresentar a estruturação e construção dos modelos a serem aplicados.

3.1 Softwares de previsão

Foi realizado um levantamento das ferramentas de previsão de demanda existentes no mercado e suas respectivas características. A partir desses dados, será justificada a escolha do *software* utilizado neste trabalho para a construção dos modelos, bem como suas vantagens perante as outras ferramentas.

Os principais *softwares* de previsão de demanda disponíveis são:

- Minitab®;
- Forecast Pro®;
- Excel®;
- OpenForecast®;
- SAS Forecast Server®;
- SPSS Trends®;
- Statgraphics®;
- StatTools®;
- SYSTAT®.

Para este trabalho, foram analisados o Minitab®, por ter sido utilizado pelo autor em matérias ministradas no curso, o Forecast Pro®, por ser uma referência no mercado e o Excel®, por ser a ferramenta mais difundida no mundo corporativo:

Minitab®

A Minitab Inc. é uma empresa privada com sede em State College, Pensilvânia, e subsidiárias no Reino Unido, na França e na Austrália. Atuando em mais de 40 países, é um dos principais provedores *softwares* e serviços estatísticos.

O *software* oferece serviços que vão além da previsão de demanda, com diferentes recursos como:

- Assistente (análise de sistemas de medição);
- Estatísticas básicas;
- Gráficos;
- Regressão;
- Análise de variância;
- Controle estatístico de processos;
- Análise dos sistemas de medição;
- Planejamento de experimentos;
- Confiabilidade–Sobrevivência;
- Poder e tamanho da amostra;
- Multivariado;
- Séries temporais e previsão;
- Funções de autocorrelação, autocorrelação parcial e correlação cruzada;
- ARIMA;
- Não paramétricos;
- Testes de equivalência;
- Tabelas (testes de qui-quadrado);
- Simulação e distribuições;
- Macros e capacidade de personalização.

Dentro de séries temporais, tema pertinente ao presente trabalho, o *software* disponibiliza:

- Gráficos de séries temporais;
- Análise de tendências;
- Decomposição;
- Média móvel;
- Suavização exponencial;
- Método de Winter.

O Minitab® calcula de maneira automática os parâmetros que minimizam o erro de previsão, além de encontrar o melhor método para cada série histórica.

Apesar de todas as vantagens, a licença apresenta um valor elevado, R\$5.300,00 para um usuário individual e treinamento básico de R\$3.800,00⁶. Além disso, não é uma ferramenta intuitiva para profissionais que não são da área – como é o caso dos colaboradores da Vinhos.Co.

Forecast Pro®

A empresa responsável pelo *software* foi fundada em 1986, tornando-se referência em previsão de demanda. As vantagens oferecidas pelo Forecast Pro® incluem a previsão de demanda de milhares de SKUs de maneira automática, com os métodos que fornecem maior acurácia para cada item, além de customizações, relatórios automáticos, previsão de produtos sem dados históricos, além de diversas outras funcionalidades. O programa inclui os seguintes itens:

- Modelos de previsão com uma opção automática "melhor escolha";
- Métodos especializados para novos produtos, itens promovidos, e eventos de forma simultânea;
- Facilidade para fazer e documentar ajustes de previsão;
- Recursos para trabalhar com várias hierarquias e unidades de medida;
- Exportação de dados via Excel®;
- Previsão vs. acompanhamento real e relatório de exceção;
- Planilhas personalizáveis que podem incluir informações importadas;
- Integração com bases de dados e sistemas corporativos.

O *software* é oferecido em três versões distintas, partindo de \$1.300,00 à \$9.000,00⁷ a licença individual. Cursos e treinamentos são oferecidos pela representante legal da empresa no Brasil, a Belge Consultoria, e os valores para cada módulo são cobrados a parte.

⁶ Valores disponíveis no site: <http://www.minitab.com/> em 10/10/2016.

⁷ Valores disponíveis no site: <http://www.forecastpro.com/> em 10/10/2016.

Excel®

Ferramenta de fácil utilização comumente encontrada no ambiente corporativo apresenta diversos recursos que possibilitam a criação de modelos de previsão de demanda.

Apesar de não apresentar a robustez dos *softwares* anteriores, atende as necessidades da empresa e pode ser facilmente implementado sem a necessidade de treinamentos externos ou a contratação de um profissional especializado.

3.1.1 Escolha do software

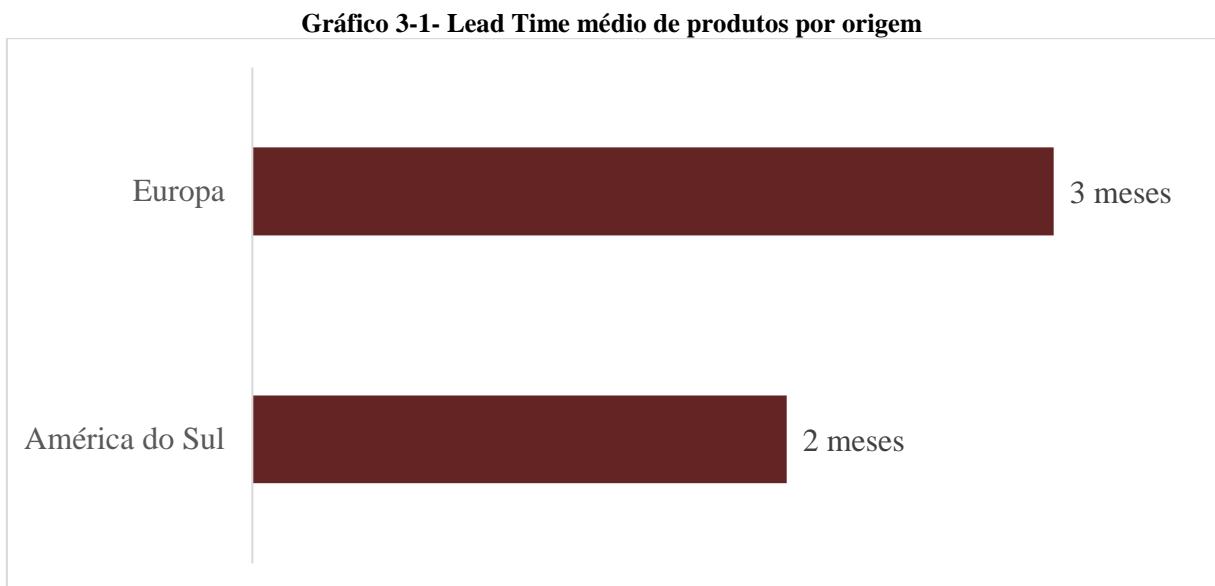
Apesar de ser mais adequado à previsão de demanda, a alta gerência da empresa definiu que não pretende investir em *softwares* robustos de revisão de demanda por dois motivos principais:

- Custo: apesar do crescimento, a empresa acabou de concluir uma fase de investimentos nas áreas comerciais que comprometeu o orçamento para novos investimentos nos próximos meses;
- Profissionalização: a empresa não possui profissionais capazes de utilizar *softwares* complexos sem treinamento ou sem novas contratações.

Era necessário, portanto, uma ferramenta com baixo ou nenhum custo de implementação, fácil de ser manipulada e de simples aceitação pelos funcionários da empresa. Tendo em vista essas limitações, a escolha do Excel® se torna interessante dado que ele consegue atender as atuais necessidades da empresa e os funcionários já fazem uso do software, facilitando a adesão.

3.2 Estrutura do modelo

O modelo foi desenvolvido com o objetivo de fornecer maior domínio sobre a demanda da companhia, permitindo melhora no processo de reabastecimento. Por isso, o horizonte de previsão foi determinado levando em consideração o período de revisão e o *lead time* de abastecimento, que é definido, neste caso, como o tempo entre a realização de um pedido para um determinado fornecedor e a chegada deste pedido à empresa.



Fonte: elaborado pelo autor com base em dados da empresa

Como mostra o Gráfico 3-1, o *lead time* dos produtos europeus são maiores do que os sul-americanos. Como margem de segurança, será adotado o maior *lead time* que a companhia apresenta: três meses. Como a análise ocorre mensalmente, o horizonte de previsão será de quatro meses, ou seja, segundo Bails e Pepper (1982), será uma previsão de curto prazo.

Dado o grande número de SKUs que a empresa possui, seria inviável a aplicação de diferentes métodos de previsão de demanda para cada SKU. Sendo assim, foi definido o nível de previsão do modelo.

Como não existia qualquer agrupamento em famílias, foi criado um critério de agrupamento para a consolidação dos SKUs em grandes grupos. Assim, o número total de amostras a serem avaliadas diminuiu drasticamente sem prejudicar a qualidade do modelo.

Os SKUs foram classificados com base em dois critérios diferentes.

Quanto ao tipo

Essa classificação se deve ao fato de que a venda dos três grupos de vinhos a seguir, se comportam de formas diferentes:

- Vinhos tintos: apresentam pico de vendas em estações frias ao longo do ano;
- Vinhos brancos: apresentam pico de vendas em estações quentes ao longo do ano;

- Vinhos espumantes: apresentam pico de vendas em épocas com datas festivas como ano novo e natal.

Quanto à demanda

Este critério é baseado na representatividade de cada produto nas vendas respeitando o diagrama de Pareto, realizando uma classificação ABC.

- A: são os 20% de SKUs que representam aproximadamente 80% das vendas. Apresentam melhores séries para previsão devido ao alto consumo;
- B: são os 30% dos SKUs seguintes que representam aproximadamente entre 15% e 19%. Características semelhantes ao anterior com um diferencial de ser um pouco mais sensível a influenciadores;
- C: os 50% restantes de SKUs que representam o restante do faturamento. A pior amostra para realizar a previsão de demanda devido à aleatoriedade apresentada por esse grupo que sofre influências muito mais impactantes por fatores externos ou internos.

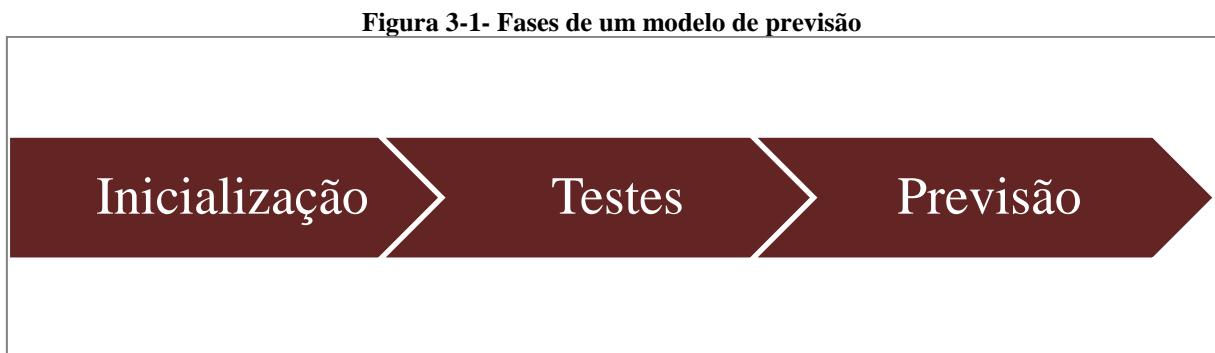
As classificações quanto ao tipo e quanto à demanda resultam em nove diferentes famílias:

- Tinto-A;
- Tinto-B;
- Tinto-C;
- Branco-A;
- Branco-B;
- Branco-C;
- Espumante-A;
- Espumante-B;
- Espumante-C.

O agrupamento não significa, entretanto, que não é possível visualizar a demanda a nível SKU. Para chegar nessa visão, deve-se realizar um rateio após a previsão da família entre os

SKUs que a compõe respeitando a representatividade de cada um, apresentada em relação aos últimos meses.

Os modelos respeitaram as fases da Figura 3-1:

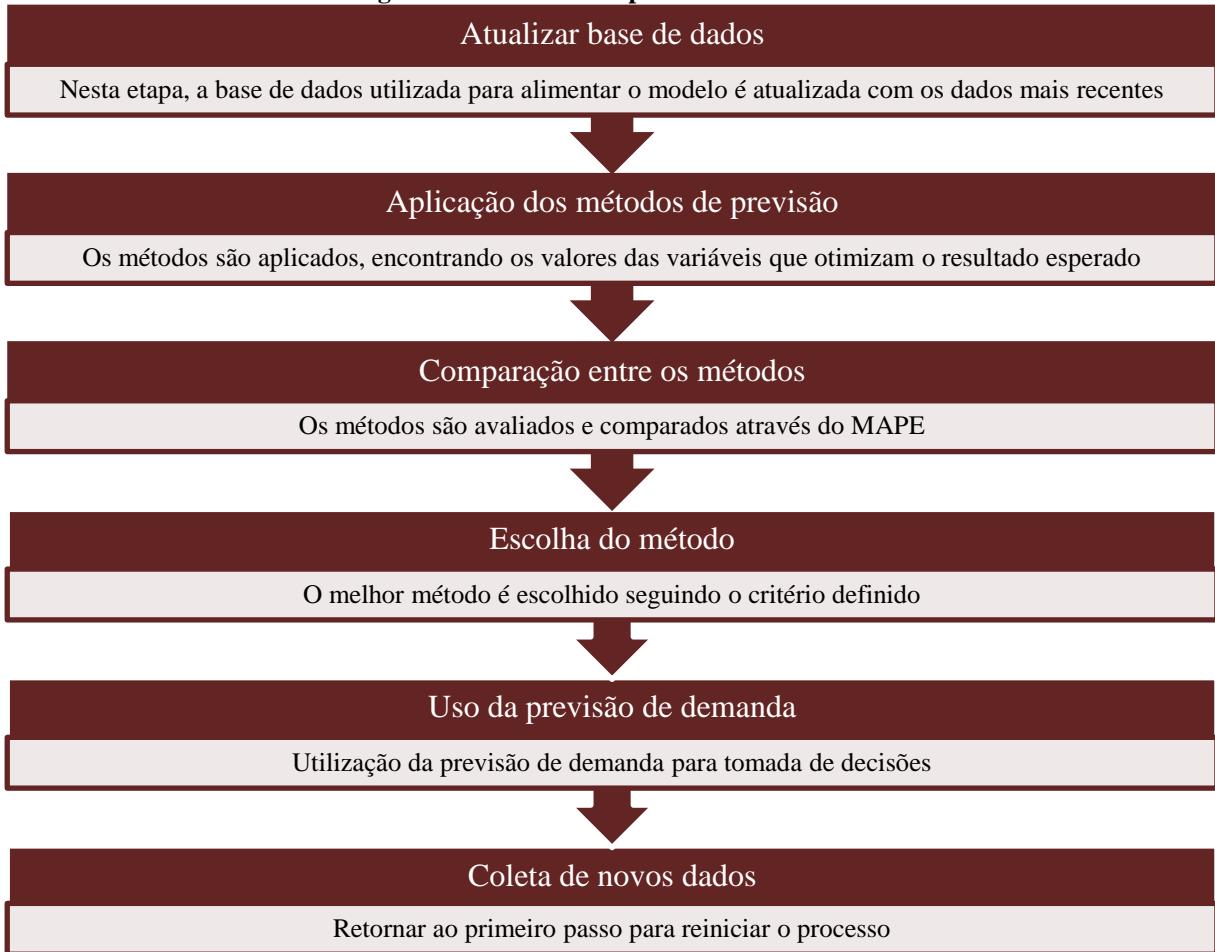


A fase de inicialização é quando o modelo inicia os seus valores, apresentando grandes erros. A fase de testes é onde ocorrem as medidas de erros, possibilitando a análise da acurácia do modelo, já que são conhecidos os dados reais deste período. Por fim, a fase de previsão é o período futuro que se deseja prever.

3.3 Processo de previsão de demanda

O objetivo do presente trabalho vai além da análise pontual da previsão de demanda da empresa. É necessário que ocorra a implementação de um processo simples de previsão com a utilização do modelo construído para que a análise da demanda ocorra de forma regular e seja utilizada pelos principais tomadores de decisões da empresa.

Neste sentido, a Figura 3-2, apresenta um processo de fácil implementação e de simples manutenção para ser utilizado pela empresa.

Figura 3-2- Processo de previsão de demanda

Fonte: Elaborado pelo autor

O presente trabalho é a primeira iteração do processo definido pela Figura 3-2. Primeiro, levanta-se os dados das séries temporais. Em seguida, são aplicados os diferentes métodos que o modelo possui. Com base no MAPE, os métodos são comparados e é escolhido o melhor para, finalmente, prever a demanda. Por fim, ocorre uma nova coleta de dados e o processo é repetido.

3.4 Levantamento de dados

O levantamento de dados é uma das primeiras etapas de um modelo de previsão e considerada como uma das etapas mais importantes.

Como o objetivo deste trabalho é realizar um modelo quantitativo e analisar seus resultados, é necessário garantir a qualidade dos dados utilizados como entradas no modelo para que não ocorram previsões distorcidas. Ainda é necessário que se utilize um intervalo de tempo suficientemente grande de dados já que a qualidade do modelo de previsão também depende da quantidade de dados disponíveis.

A Vinhos.Co utiliza atualmente uma solução de *Business Intelligence* oferecida pela TOTVS® chamada *GooDdate®*, que está ligado diretamente ao *Enterprise Resource Planning* (ERP) da empresa e disponibiliza os dados de vendas por SKU desde janeiro de 2014.

Nesta parte do trabalho foi adotado a premissa de que os dados de venda dos SKUs correspondem à demanda do mesmo. Isto se deve ao fato de que a empresa não possui dados referentes à demanda de cada produto, ou seja, não existe um histórico apontando quando determinado produto não estava disponível mas havia demanda naquele período.

Apesar de não ser o ideal, esta premissa faz especial sentido no mercado em questão devido à dois pontos principais:

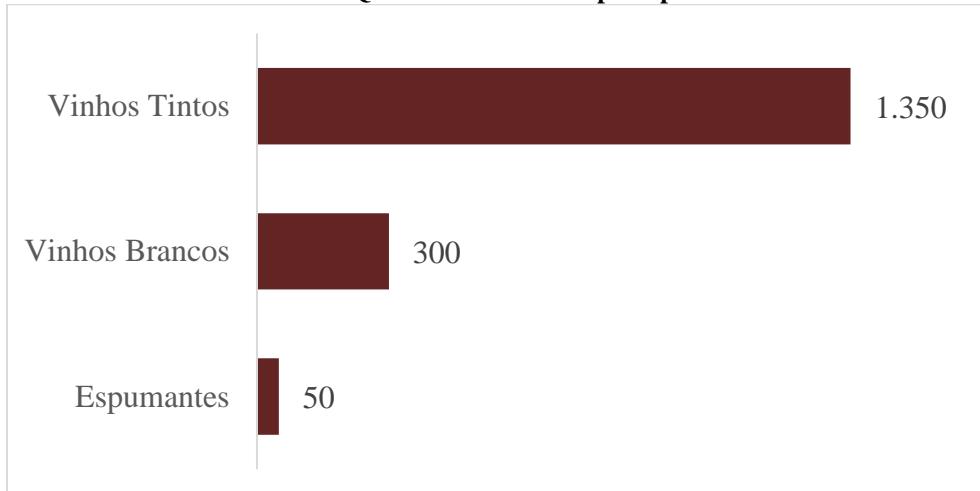
- O mercado de vinhos apresenta uma variedade de produtos substitutos totalmente fora de escala se comparado a outros setores. No caso da Vinhos.Co mais de 1500 SKUs disponíveis. Isso faz com que uma demanda relacionada à um determinado SKU que está em falta, dificilmente não seja atendida pela alta variedade de produtos substitutos que a empresa possui;
- Como o modelo agrupou os SKUs em famílias e a empresa sempre apresenta alto nível de estoque, podemos considerar que a falta de demanda foi compensada por produtos similares dentro da mesma família, não resultando em grandes impactos nas vendas.

Com isso, o trabalho irá utilizar os dados históricos de vendas como aproximação da demanda da empresa.

As informações de vendas extraídas do sistema são sempre relacionadas à quantidade total de garrafas vendidas por SKU, fornecendo uma unidade de medida satisfatória e comparável.

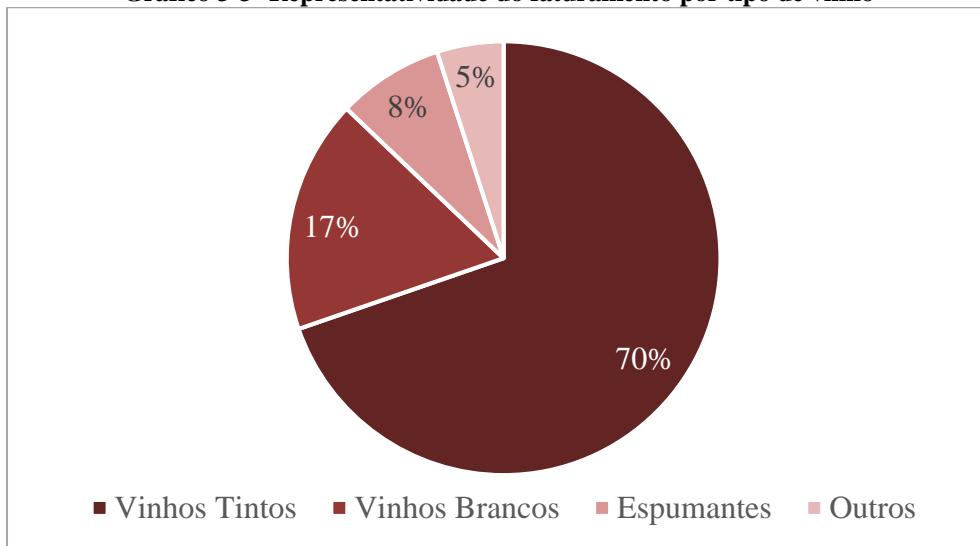
O nível de agregação temporal dos dados utilizados no presente trabalho é mensal. Apesar do sistema conseguir fornecer dados diários de vendas, o agrupamento mensal é uma medida mais adequada devido às reuniões mensais de planejamento.

Para a classificação das famílias, foram utilizados critérios já apresentados no presente trabalho. O critério de classificação por tipo de vinho, resultou em uma separação dos SKUs ilustrada no Gráfico 5-2:

Gráfico 3-2- Quantidade de SKUs por tipo de vinho

Fonte: elaborado pelo autor com base em dados da empresa

Como mostra o Gráfico 3-2, a quantidade de SKUs de vinhos tintos é predominantemente maior do que as outras duas categorias. Isto não retira a importância das outras duas categorias que possuem papel estratégico em determinadas épocas do ano devido à sazonalidade da demanda destes produtos.

Gráfico 3-3- Representatividade do faturamento por tipo de vinho

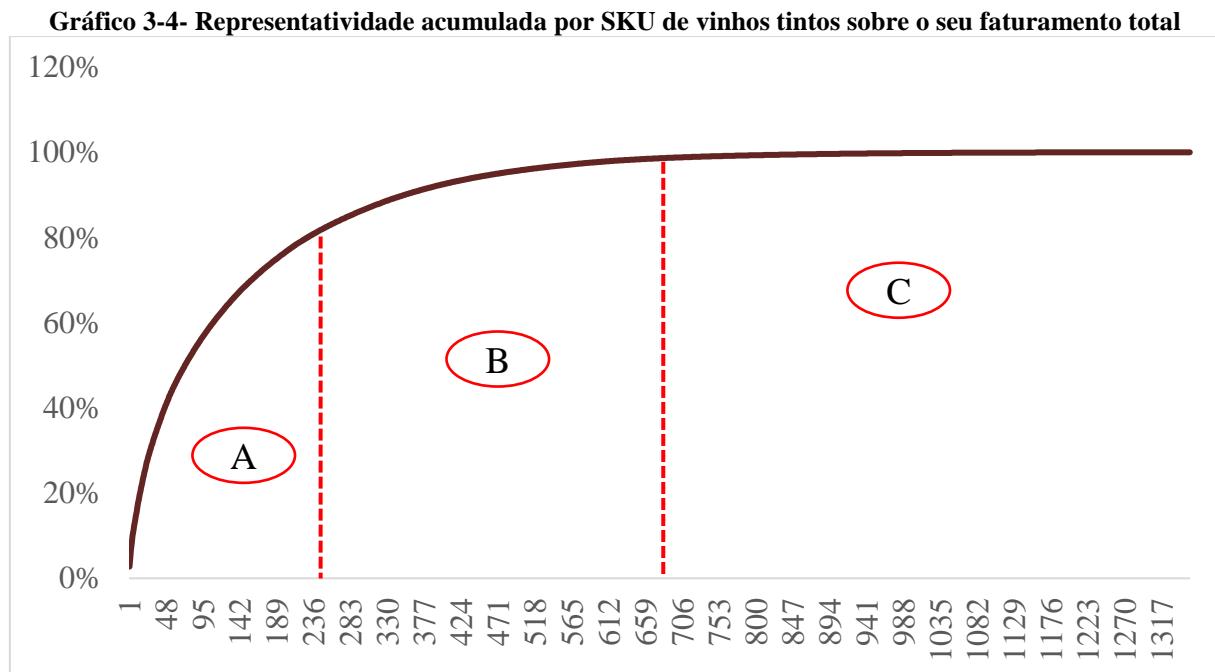
Fonte: elaborado pelo autor com base em dados da empresa

Como mostra o Gráfico 3-3, apesar dos espumantes representarem menos de 3% da quantidade total de rótulos, estes são responsáveis por 8% do faturamento da empresa.

“Outros” são produtos como licores, *grappas* e outras classificações de vinhos como vinhos de sobremesa e vinhos fortificados. Por representarem uma parte pequena do faturamento, não serão analisados neste trabalho.

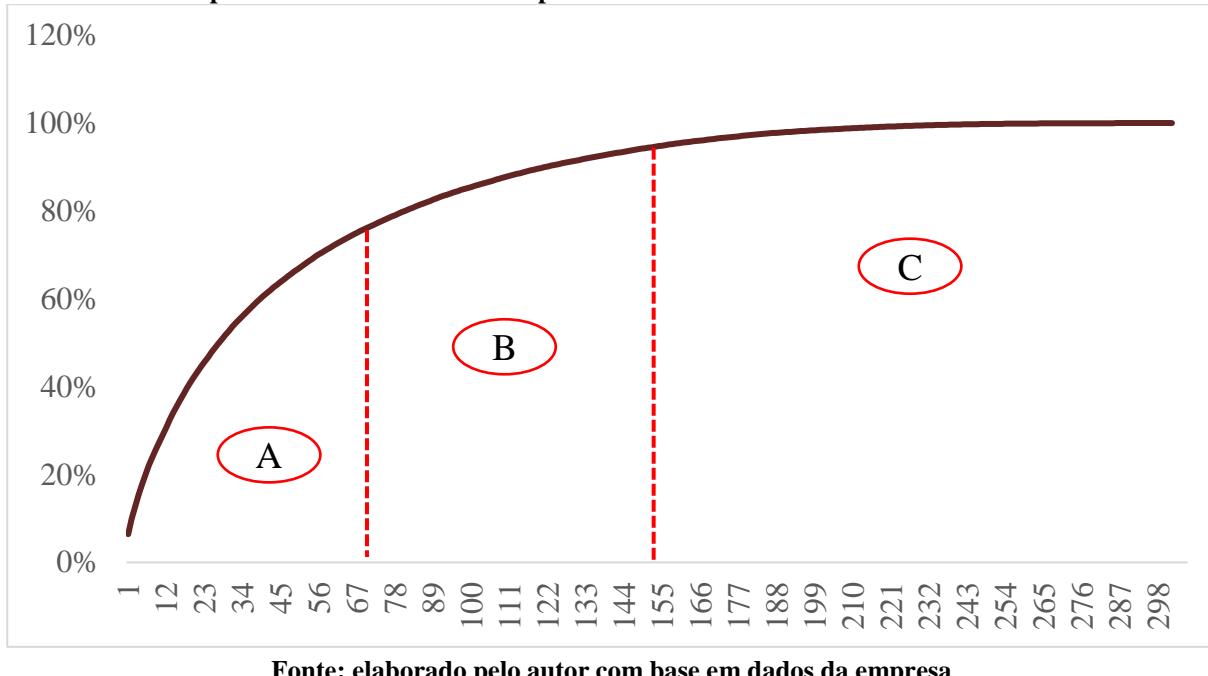
A segunda classificação adotada diz respeito à representatividade do faturamento que cada SKU apresenta dentro dos seus respectivos tipos.

Para isso foi realizada uma classificação ABC baseada no diagrama de Pareto. A seguir serão apresentados os diagramas para os três tipos de vinhos.



Fonte: elaborado pelo autor com base em dados da empresa

É possível observar no Gráfico 3-4 que aproximadamente 250 SKUs são responsáveis por 80% do faturamento dos vinhos tintos e constituem a família Tintos-A.

Gráfico 3-5- Representatividade acumulada por SKU de vinhos brancos sobre o seu faturamento total

Fonte: elaborado pelo autor com base em dados da empresa

Nota-se no Gráfico 3-5 que mais de 150 SKUs representam menos de 5% do faturamento dos vinhos brancos.

Gráfico 3-6-Representatividade acumulada por SKU de espumantes sobre o seu faturamento total

Fonte: elaborado pelo autor com base em dados da empresa

O Gráfico 3-6 mostra que a curva dos espumantes apresenta uma particularidade: um único SKU é responsável por, aproximadamente, 20% do faturamento dos espumantes. Vale ressaltar

que existem apenas 50 SKUs de espumantes, o que torna o fato menos significativo caso fosse observado nos vinhos tintos.

3.5 Análise preliminar dos dados

Será apresentada uma análise preliminar em torno das séries históricas coletadas referentes às famílias de produtos da empresa. Apenas as famílias Tintos-A, Brancos-A e Espumantes-A serão analisadas neste trabalho devido às suas características distintas e à sua maior representatividade dentro do portfólio da companhia, sendo responsável por aproximadamente 80% da receita.

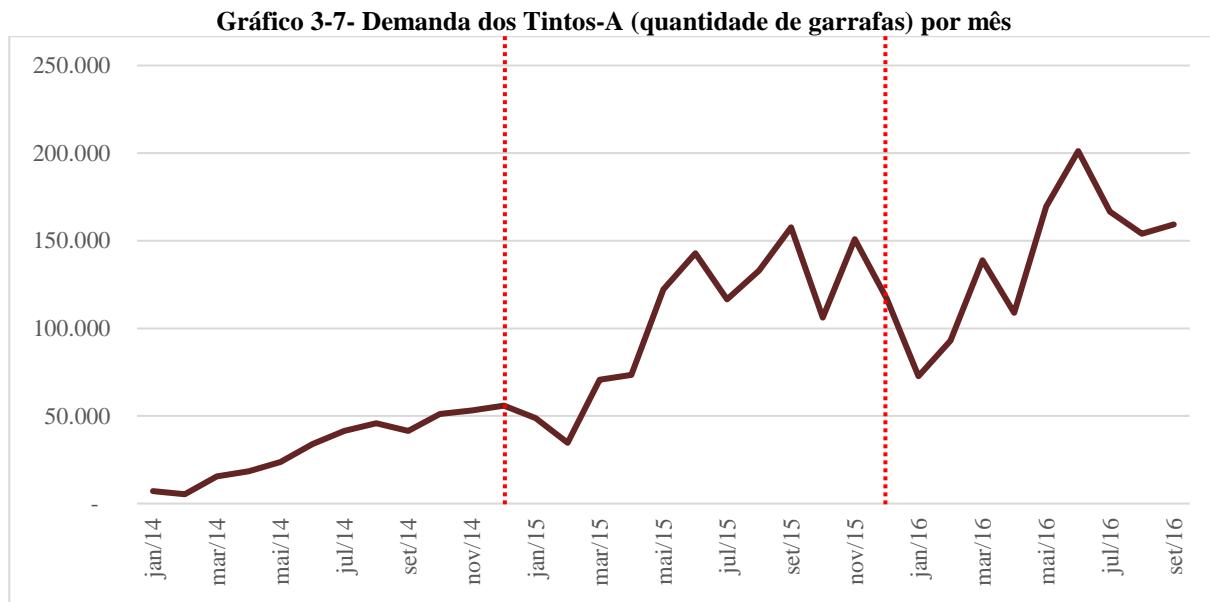
A análise preliminar tem por objetivo conhecer o comportamento das séries e identificar características como sazonalidade, tendência e aleatoriedade.

Nos próximos tópicos serão apresentadas as curvas das demandas das famílias selecionadas com uma breve descrição sobre o comportamento destas complementando com conhecimentos mercadológicos adquiridos ao longo do estágio do autor.

3.5.1 Tintos-A

Os vinhos tintos representam 69% do faturamento da empresa, tendo um papel central na companhia. Desse faturamento, os Tintos-A constituem 84%, ou 56% do faturamento total. A sua representatividade evidencia a importância de possuir um modelo de previsão de demanda assertivo.

A demanda de vinhos tintos vem crescendo fortemente nos últimos anos no país que é dominado pela cultura da cerveja. O Brasil passa por um processo de incorporação da bebida à mesa do consumidor, sendo cada vez mais comum o consumo durante refeições e em restaurantes e bares noturnos (ALMEIDA; BRAGAGNOLO; CHAGAS, 2015).



No Gráfico 3-7, pode-se perceber que a demanda apresenta uma tendência de crescimento condizente com o aumento da empresa nos últimos anos. O método de Holt-Winters apresenta soluções de tratamento para casos como o do Vinhos-A.

Além da tendência, é possível perceber sazonalidade com período em torno de um ano. O ponto de menor venda de vinhos tintos ocorre entre fevereiro e março, seguido por um aumento considerável nos meses seguintes, até dezembro, onde entra em uma tendência de queda novamente.

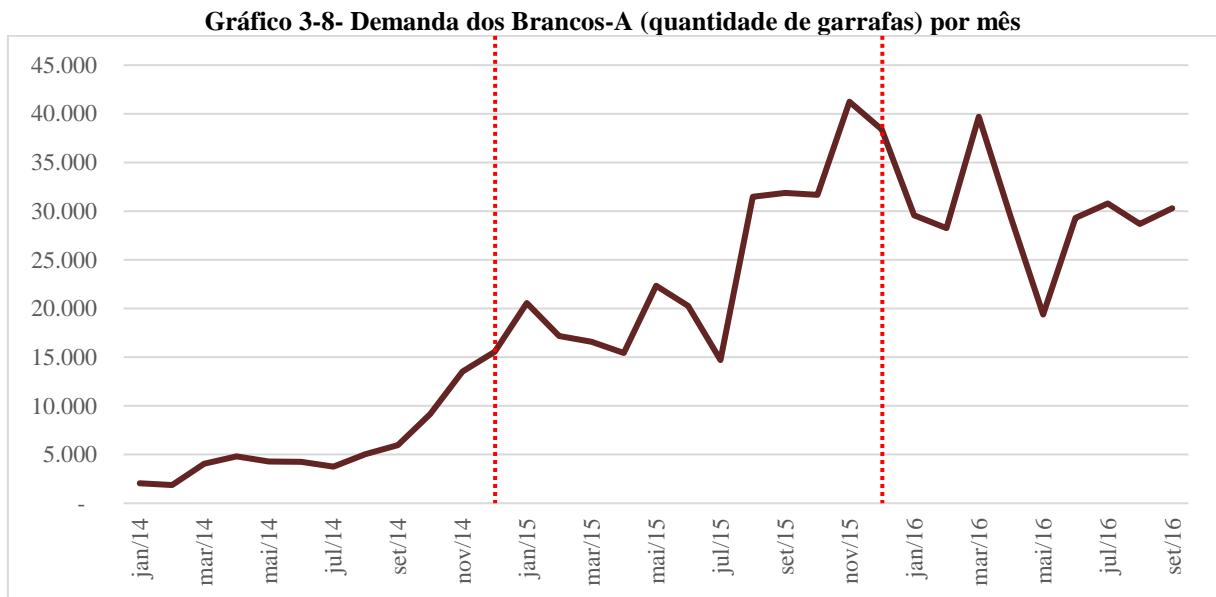
3.5.2 Brancos-A

Apesar do Brasil apresentar clima tropical e diversos tipos de pratos de peixes, frutos do mar, frutas e saladas, que são harmonizações perfeitas para vinhos brancos, estes ainda possuem pouco prestígio na mesa do consumidor brasileiro. Segundo Ibravin (2008), o vinho branco é preferência para menos de 25% dos consumidores de vinhos finos.

Na VinhosCo., o cenário de venda dos vinhos brancos é bem semelhante ao encontrado no país. Este tipo de vinho representa quase 1/3 do comércio dos tintos, ou 22% do faturamento da empresa. Dessa forma, durante muitos anos, os vinhos brancos foram ignorados pelos importadores, o que resultou em pouca variedade de rótulos para o consumidor final.

Entretanto, nos últimos anos, produtores e importadores vêm se esforçando para mudar o comportamento do consumidor. Em 2012, já foi possível ver os resultados dessas medidas: o

consumo de vinho branco subiu 4% em dois anos⁸. É possível ver essa tendência de crescimento até mesmo nas importações feitas pela VinhosCo, que hoje já conta com mais de 300 rótulos de vinhos brancos.



Fonte: elaborado pelo autor com base em dados da empresa

Como mostra o Gráfico 3-8, a demanda dos Brancos-A apresenta tendência de alta ao longo dos últimos anos. É possível perceber uma sazonalidade na curva, em que a demanda diminui nos meses frios – como junho e julho – e aumenta nos meses de altas temperaturas.

3.5.3 Espumantes-A

O consumo de espumantes ainda enfrenta maiores barreiras na mesa dos brasileiros do que os vinhos brancos. É um produto que não é visto com naturalidade para consumo em ocasiões comuns: para consumidores típicos, o consumo de espumantes ocorre apenas em celebrações (IBRAVIN,2008).

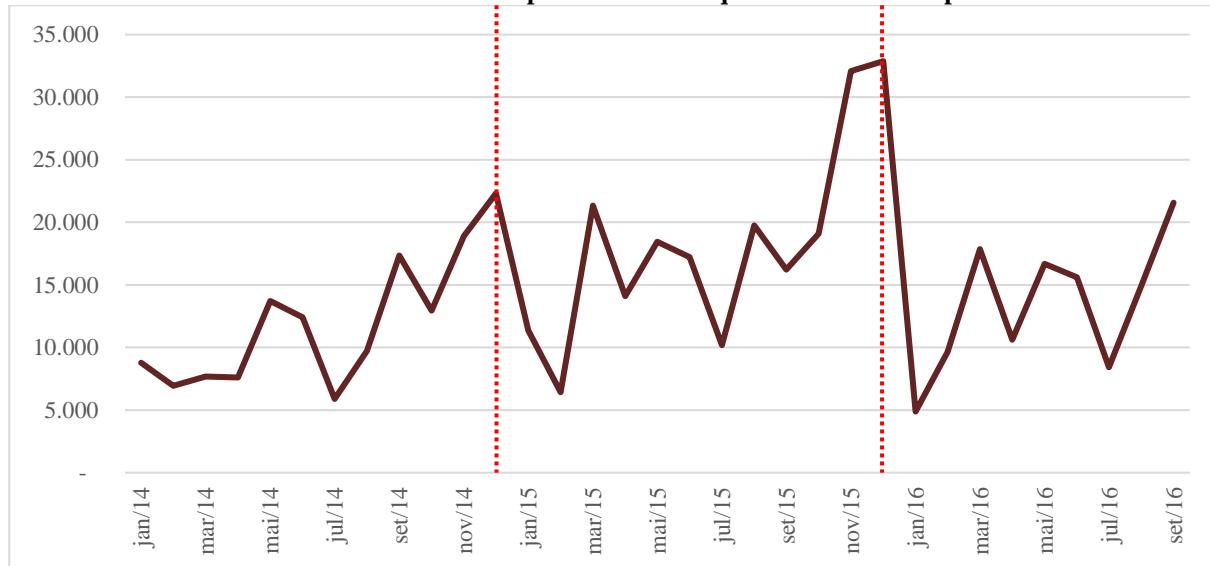
O consumo de espumantes no país é ligado tradicionalmente à grandes festas e comemorações, como casamentos e ano novo. Essa tradição pode ser explicada por, entre outros fatores, as características da bebida (IBRAVIN,2008).

Muitos consumidores ignoram o fato do espumante ser um tipo de vinho feito com uvas predominantemente tintas devido ao nível significativo de dióxido de carbono contido neste

⁸ Pesquisa elaborada pela consultoria WineIntelligence e publicada pela FecomércioSP em 2012.

produto que resulta no seu grande diferencial: o borbulhar. As bolhas dos espumantes são resultados da fermentação natural que pode ocorrer dentro da garrafa (método *Champenoise*) ou nos tanques de descanso, antes de ocorrer o engarrafamento do produto (método *Charmat*). Essas características, para o consumidor, são bastante relacionadas com requinte e celebrações – o que explica a sazonalidade das vendas do produto.

Gráfico 3-9- Demanda dos Espumantes-A em quantidade de SKU por mês



Fonte: elaborado pelo autor com base em dados da empresa

O Gráfico 3-9 mostra como o consumo de espumantes apresenta picos em novembro e dezembro devido às festas de fim de ano, seguidos por uma queda brusca nos dois meses seguintes. Após fevereiro, a demanda estabiliza em um patamar intermediário até o fim do ano novamente.

Apesar do consumo em dezembro de 2015 ter sido significativamente maior do que no mesmo período do ano anterior, não existe uma tendência clara na demanda deste tipo de produto.

4 MODELOS DE PREVISÃO DE DEMANDA NA VINHOS.CO

Este capítulo destina-se a explicar detalhadamente os passos seguidos para a elaboração de cada um dos modelos que foram construídos no *software Excel®*. Foram elaboradas nove planilhas distintas, uma para a base de dados, sete para os modelos de previsão testados e uma de resumo geral, comparando os resultados obtidos em cada método. Cada modelo serve para as três famílias de produtos analisados, podendo ser alterado todo o modelo simplesmente selecionando a opção que se deseja modelar.

Para a otimização dos parâmetros α , B e γ foi utilizado o Solver, uma das ferramentas contidas no teste de hipótese do Excel®. O Solver é uma ferramenta que encontra o resultado esperado de uma célula objetivo, alterando variáveis de decisões e respeitando restrições definidas. No presente estudo, a célula objetiva é aquela que mostra como *output* o MAPE e a intenção da ferramenta é encontrar os valores das variáveis que minimizam o MAPE.

Todas as planilhas de modelagem foram construídas em cima de uma estrutura comum para, em seguida, ser adicionado as particularidades referentes à cada modelo.

A parte superior das planilhas ficou reservada para variáveis de controle, como:

- Tipo de família: uma célula onde ocorre a seleção da família a ser utilizada no modelo (Tintos-A, Brancos-A ou Espumantes-A);
- α : a constante de suavização do nível para os casos necessários;
- β : a constante de suavização da tendência para os casos necessários;
- γ : a constante de suavização da sazonalidade para os casos necessários;
- MSE: *mean squared error*, medida de erro demonstrada na literatura dada pela seguinte fórmula:

$$MSE = \frac{1}{n} \sum_{t=1}^n e_t^2$$

- MAPE: *mean absolute percentage error*, medida de erro demonstrada pela literatura dada pela seguinte fórmula:

$$MAPE = \frac{1}{n} \sum_{t=1}^n |PE_t|$$

- Quantidade de períodos utilizado para o cálculo da média móvel.

Logo abaixo encontra-se uma tabela com as colunas a seguir:

- Períodos mensais;
- Meses dos anos;
- Y_t : dados históricos observados no período t;
- F_t : previsão realizada no período t;
- $e_t = Y_t - F_t$;
- $PE = \frac{e_t}{Y_t}$;
- $|PE| = \left| \frac{e_t}{Y_t} \right|$;
- $PE^2 = \left(\frac{e_t}{Y_t} \right)^2$.

No lado superior direito da planilha, encontra-se um gráfico que inclui os dados históricos e a previsão realizada pelo modelo.

No lado inferior direito da planilha, encontra-se um estudo de sensibilidade do MAPE em relação as variáveis α e β nos casos em que se faz uso destas.

A seguir serão apresentados maiores detalhes referentes a implementação de cada modelo.

4.1 Modelo de Médias Móveis

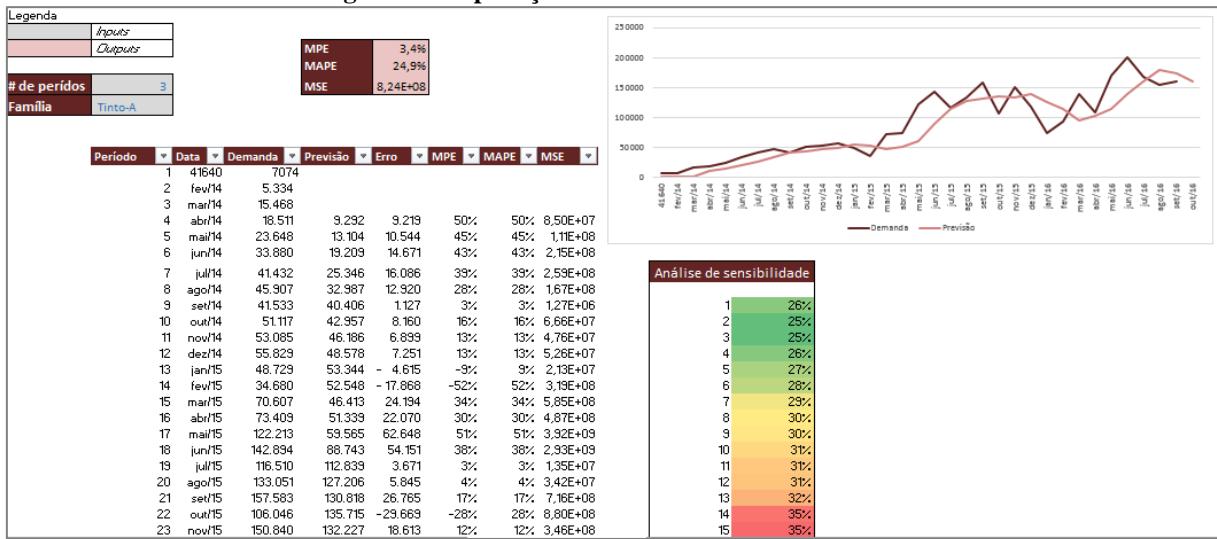
O modelo de média móvel foi analisado para diferentes tipos de k, quantidade de períodos da fórmula:

$$F_{t+1} = \frac{1}{k} \sum_{i=t-k+1}^t Y_i$$

Foi construído uma análise de sensibilidade para analisar como o MAPE variava com diferentes tipos de k. o objetivo dessa análise tem por objetivo encontrar o k que minimiza o MAPE.

Na Figura 4-1 é possível ver a tela do modelo construído:

Figura 4-1- Aplicação do método de médias móveis



Fonte: Captura de tela do sistema desenvolvido pelo autor

4.2 Modelo de Suavização Exponencial Simples

Para a inicialização deste modelo, deve-se assumir uma hipótese na estimativa do primeiro valor de previsão.

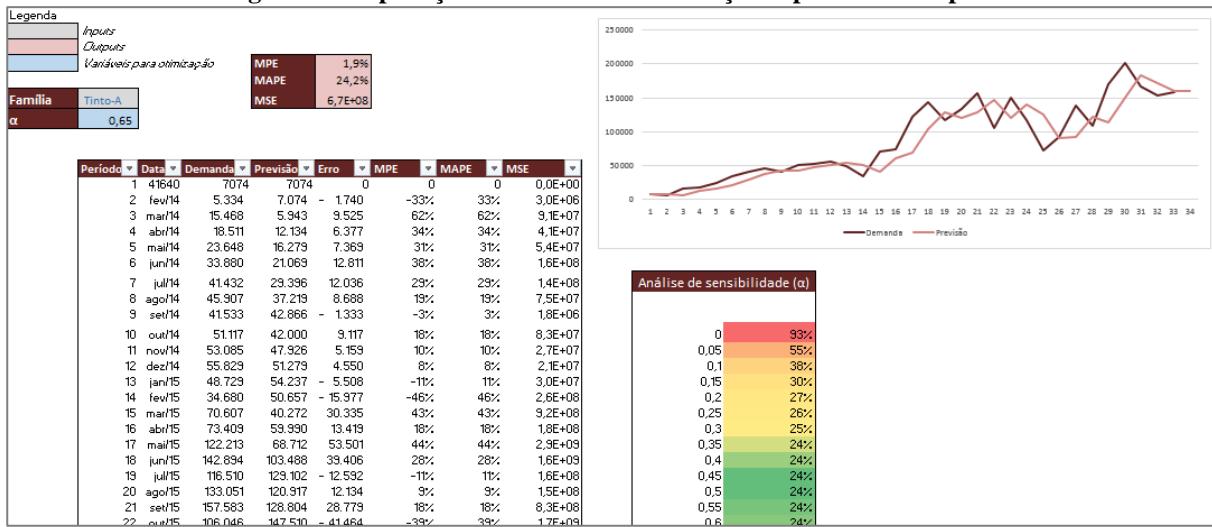
$$F_{t+1} = F_t + \alpha (Y_t - F_t)$$

Pode-se reparar na equação do método que para calcular F_2 é necessário que se tenha F_1 . Makridakis et al. (1998) sugere dois métodos de inicialização:

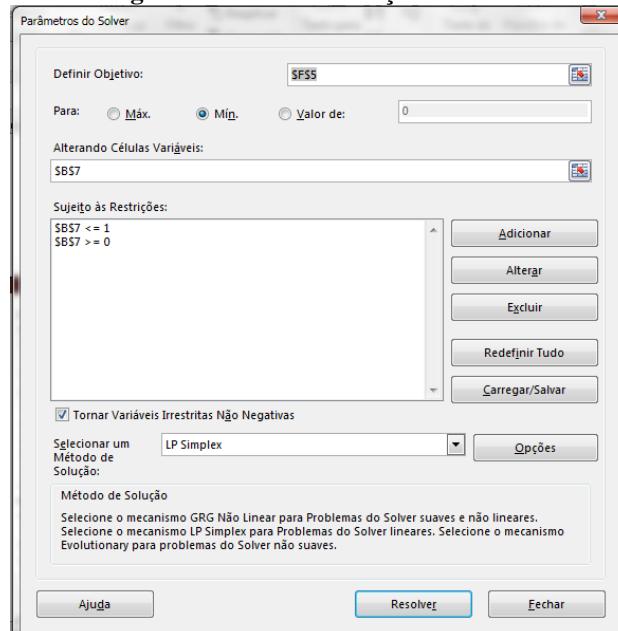
- Considerar a primeira observação como o valor da primeira previsão, ou seja, $F_1 = Y_1$;
- Considerar a média dos primeiros quatro dados observados como a primeira previsão, ou seja, $F_1 = \sum_{n=1}^4 Y_n / 4$.

Neste trabalho optou-se pela primeira opção por ser a mais utilizada na literatura.

Para rodar o Solver, foi considerado um valor inicial de $\alpha = 0,2$.

Figura 4-2- Aplicação do método de suavização exponencial simples**Fonte:** Captura de tela do sistema desenvolvido pelo autor

Para encontrar o α que resulta no menor MAPE, além da análise de sensibilidade, na parte inferior direita da Figura 4-2, foi utilizado a ferramenta *Solver* como explicado anteriormente. A Figura 4-3 ilustra a utilização da ferramenta para a parametrização do modelo.

Figura 4-3- Parametrização do Solver**Fonte:** Captura da tela do Solver parametrizado pelo autor

4.3 Modelo de Suavização Exponencial com Tendência

Para a utilização deste modelo, também é necessário que se faça uma estimativa para os valores iniciais de nível e tendência.

Makridakis et al. (1998) sugerem dois métodos de inicialização:

- Considerar $L_1 = Y_1$; $b_1 = Y_2 - Y_1$ ou $b_1 = \frac{Y_4 - Y_1}{3}$;
- Chegar ao valor de L_1 e b_1 utilizando regressão de mínimos quadrados.

Foi utilizado o primeiro método de inicialização neste estudo devido à sua simplicidade.

Neste modelo, também foram incluídas duas colunas na tabela da parte inferior:

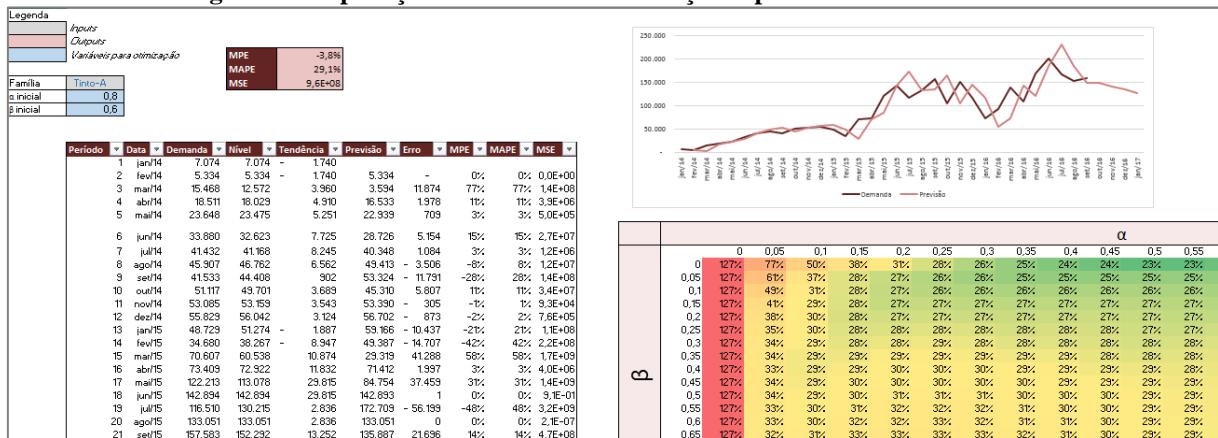
- Coluna referente ao nível (L_t), calculado pela seguinte equação:

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

- Coluna referente à tendência (b_t), calculada pela seguinte equação:

$$b_t = \beta(L_t + L_{t-1}) + (1 - \beta)b_{t-1}$$

Figura 4-4- Aplicação do método de suavização exponencial com tendência

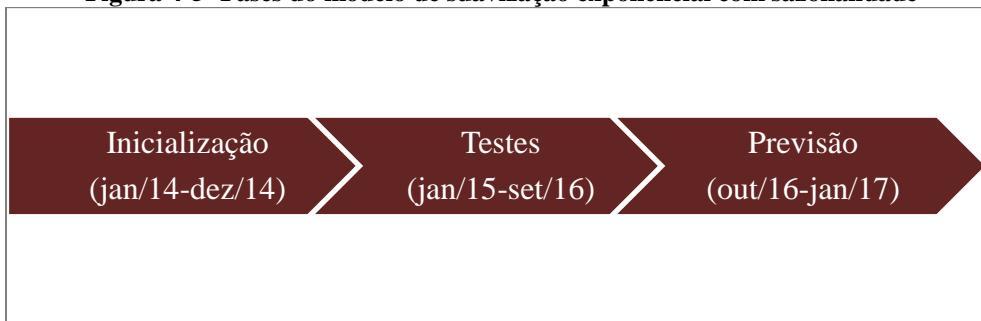


Fonte: Captura de tela do sistema desenvolvido pelo autor

Na Figura 4-4 é possível ver a análise de sensibilidade do modelo, a previsão de demanda para os meses seguintes e os valores otimizados das variáveis.

4.4 Modelo de Suavização Exponencial com Sazonalidade

O período de inicialização consta dos 12 primeiros meses e é necessário para a estimativa dos coeficientes de sazonalidade iniciais. Pode-se ver as fases do modelo de suavização exponencial com sazonalidade na Figura 6-5.

Figura 4-5- Fases do modelo de suavização exponencial com sazonalidade

Fonte: Elaborado pelo autor

Para o modelo de suavização exponencial com sazonalidade, foram incluídas colunas de nível e de sazonalidade, além de uma tabela inicial com os coeficientes de sazonalidade de *inputs* e o nível da série estimado no instante zero.

Primeiro foi considerado que o comprimento da sazonalidade dos produtos é de um ano, ou seja, $s=12$.

A segunda consideração adotada no modelo foi para o cálculo de L_0 , dado pela seguinte equação:

$$L_0 = \frac{\sum_{t=1}^{12} Y_t}{12}$$

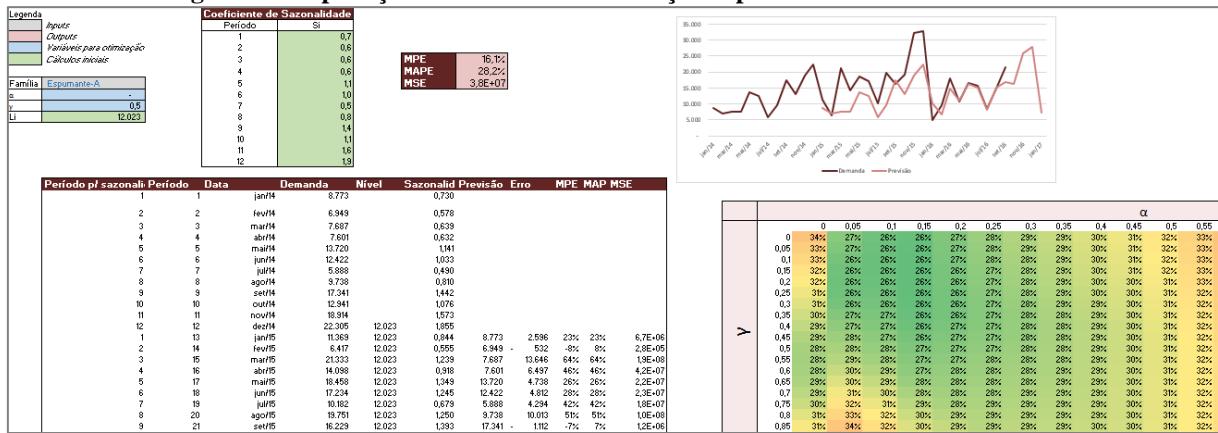
Com isso foi possível calcular os coeficientes de sazonalidade iniciais por meio da seguinte fórmula:

$$S_t = \frac{Y_t}{L_0}$$

Com $1 \leq t \leq 12$. Para os casos onde $t > 12$, foi utilizado a equação mostrada na revisão da literatura.

Pode-se notar na Figura 4-6, os valores em branco para as colunas de nível e previsão para os 12 primeiros meses, que correspondem ao intervalo de sazonalidade.

Figura 4-6- Aplicação do método de suavização exponencial com sazonalidade

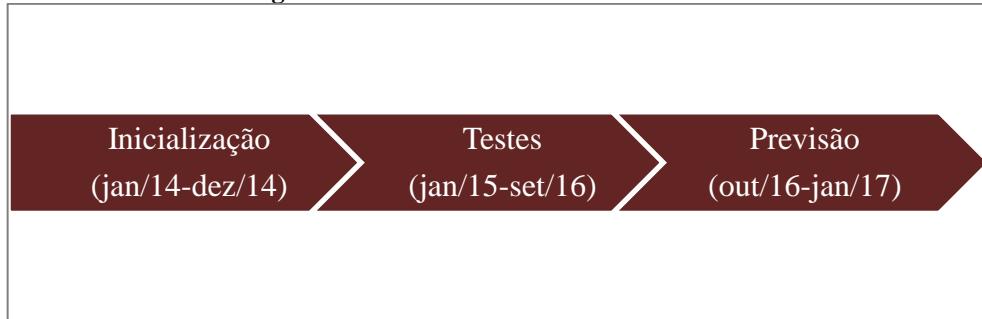


Fonte: Captura de tela do sistema desenvolvido pelo autor

4.5 Modelo de Suavização Exponencial com Tendência e Sazonalidade Multiplicativa

O modelo foi construído seguindo as fases apresentada na Figura 4-7:

Figura 4-7- Fases do modelo de Holt-Winters



Fonte: Elaborado pelo autor

Foram inseridas três colunas na tabela de cálculos para esse modelo: a primeira referente ao nível, a segunda referente a tendência e a terceira referente a sazonalidade. Além disso, foram adicionados:

- Campo de cálculo para L_{12} dado pela seguinte equação:

$$L_{12} = \frac{\sum_{t=1}^{12} Y_t}{12}$$

- Campo de cálculo para b_{12} dado pela seguinte equação:

$$b_{12} = \frac{(\sum_{t=13}^{24} Y_t - \sum_{t=1}^{12} Y_t)}{12^2}$$

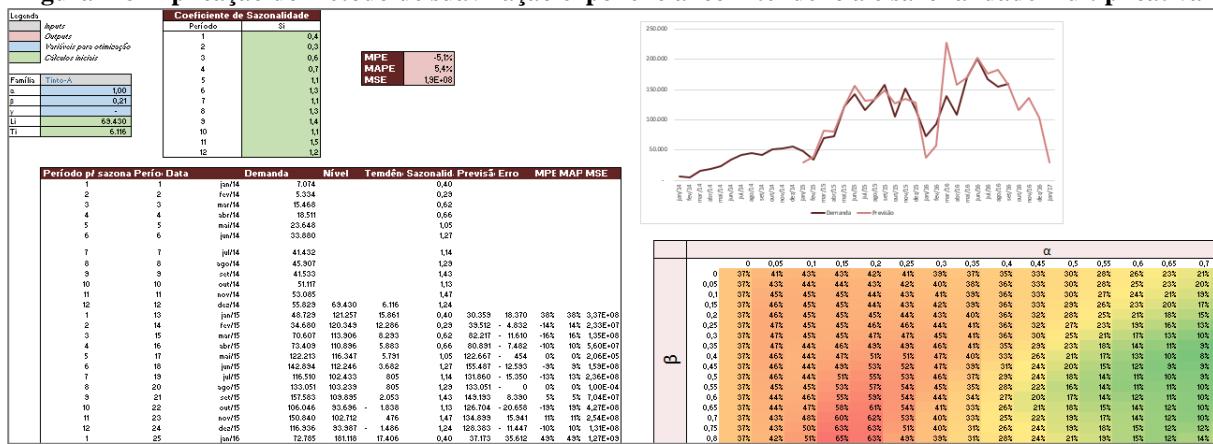
- Tabela com o componente sazonal no período de inicialização ($1 \leq t \leq 12$), dado pela seguinte equação:

$$S_t = \frac{Y_t}{L_{12}}$$

- Adotou-se $m = 1$ ($m =$ número de períodos que se deseja prever) durante as fases de inicialização e teste. Para a fase de previsão, m varia de um à quatro.

A Figura 4-8 ilustra a disposição do modelo, com os coeficientes de sazonalidades calculados na parte superior da tabela, com fundo verde.

Figura 4-8- Aplicação do método de suavização exponencial com tendência e sazonalidade multiplicativa



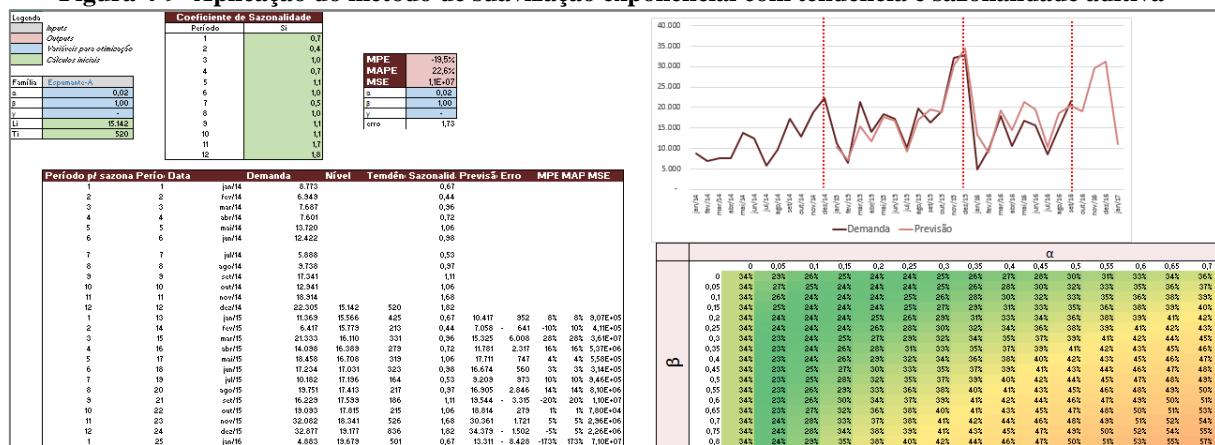
Fonte: Captura de tela do sistema desenvolvido pelo autor

4.6 Modelo de Suavização Exponencial com Tendência e Sazonalidade Aditiva

Este método seguiu as mesmas diretrizes do método anterior com as adaptabilidades que a sazonalidade aditiva requer.

Como a Figura 4-9 mostra, não há diferenças visíveis entre a tela dos modelos de Holt-Winters com sazonalidade aditiva ou multiplicativa.

Figura 4-9- Aplicação do método de suavização exponencial com tendência e sazonalidade aditiva



Fonte: Captura de tela do sistema desenvolvido pelo autor

5 ANÁLISE DOS RESULTADOS

Neste capítulo serão analisados os resultados obtidos nas simulações para as três famílias de produtos analisadas no presente trabalho:

- Tintos-A;
- Brancos-A;
- Espumantes-A.

As demandas de cada produto foram analisadas com a utilização de sete métodos quantitativos:

- Média Simples;
- Média Móvel;
- Suavização Exponencial Simples;
- Suavização Exponencial com Tendência;
- Suavização Exponencial com Sazonalidade;
- Holt-Winters com sazonalidade multiplicativa;
- Holt-Winters com sazonalidade aditiva.

A seguir serão apresentados os resultados das análises para cada família de produtos.

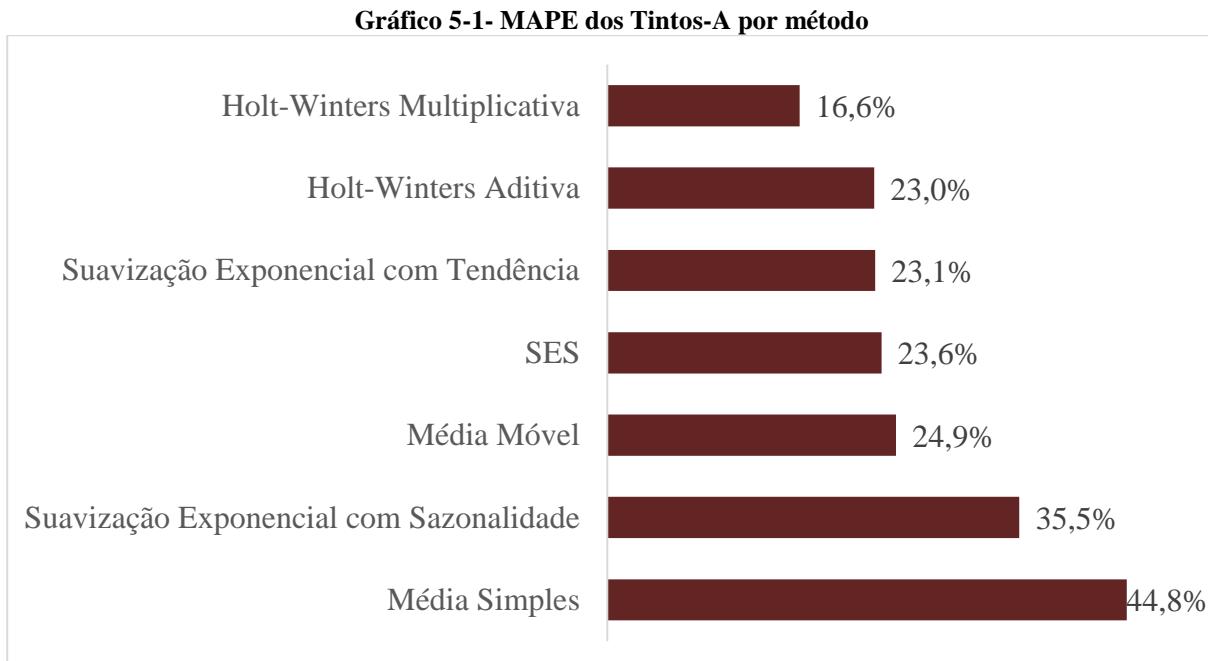
5.1 Tintos-A

Para os Tintos-A, os métodos de Holt-Winters multiplicativo, suavização exponencial com tendência e suavização exponencial simples apresentaram melhores resultados do que o resultado obtido pelo método atual de previsão utilizado na Vinhos.Co (média móvel simples com dois períodos). Enquanto os métodos de suavização exponencial com sazonalidade e média simples apresentam os piores resultados.

Os métodos estão listados a seguir do melhor para o pior:

- Holt-Winters Multiplicativa;
- Holt-Winters Aditiva;
- Suavização Exponencial com Tendência;
- SES;
- Média Móvel;

- Suavização Exponencial com Sazonalidade;
- Média Simples.



Fonte: Elaborado pelo autor

Como pode-se ver no Gráfico 5-1, nem sempre os métodos mais complexos apresentam os melhores resultados. Apesar do pior resultado ser de média simples, já esperado se levado em consideração o Gráfico 3-7- Demanda dos Tintos-A (quantidade de garrafas) por mês, devido à tendência apresentada, o método de suavização exponencial com sazonalidade apresentou resultado 43% pior do que o método de média móvel simples.

Além disso, os métodos de Holt-Winters aditiva, suavização exponencial com tendência e SES não apresentaram resultados muito superiores aos obtidos com a média móvel.

Na Tabela 5-1, percebe-se que o método de Holt-Winters com tendência multiplicativa apresentou o melhor resultado para os Tintos-A, com melhora de 33% ou 8,3 pontos percentuais em relação ao método atual da Vinhos.Co (média móvel com dois períodos).

Tabela 5-1- Detalhes dos resultados obtidos para Tintos-A

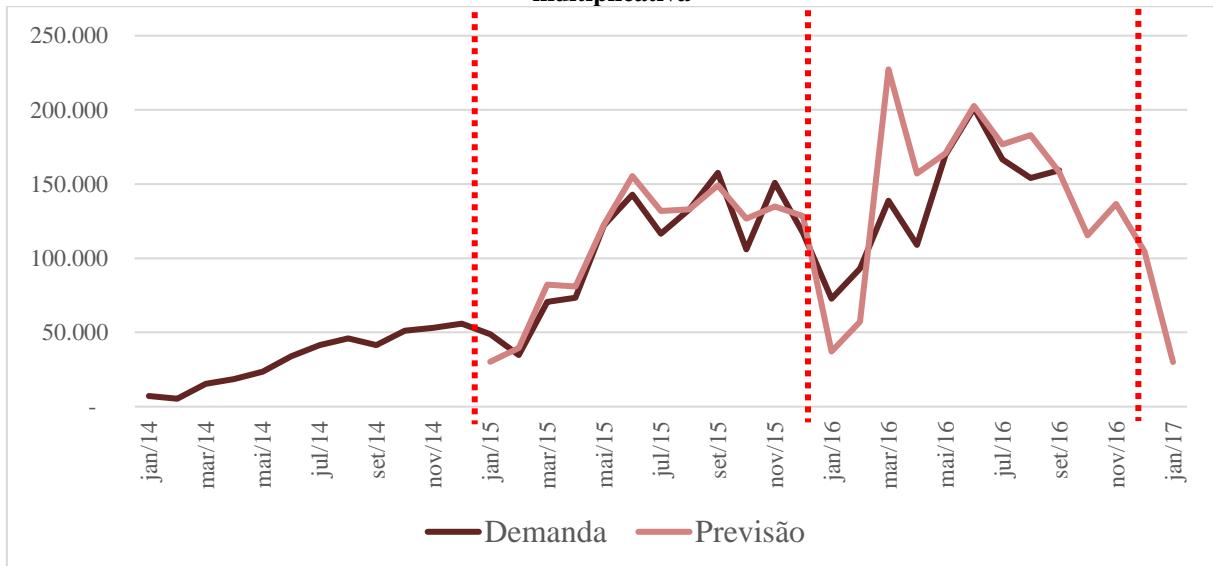
Tintos-A	MSE	MAPE	Maior PE	n	α	β	γ
Média Simples	4,6E+09	44,8%	65,6%				
Média Móvel	7,8E+08	24,9%	83,9%	2			
SES	7,2E+08	23,6%	74,9%		0,48		
Suavização Exponencial com Tendência	8,0E+08	23,1%	69,8%		0,52	-	
Suavização Exponencial com Sazonalidade	2,0E+09	35,5%	76,2%		0,09		0,40
Holt-Winters Aditiva	2,3E+09	23,0%	53,9%		0,03	1,00	-
Holt-Winters Multiplicativa	1,7E+08	16,6%	65,0%		1,00	0,23	-

Fonte: Elaborado pelo autor

Apesar do método de Holt-Winters apresentar o menor MAPE e o menor MSE entre os métodos analisados, o maior erro observado para um período (maior |PE|) deste método não apresenta resultado significativamente melhor do que os demais.

Na verdade, o método de Holt-Winters apresenta o “Maior |PE|” semelhante ao método da média simples, que foi avaliado como o pior método para os Tintos-A.

Este erro encontra-se no mês de março de 2016, como apresentado no Gráfico 5-2.

Gráfico 5-2- Resultado da previsão de Tintos-A utilizando o método de Holt-Winters com sazonalidade multiplicativa

Fonte: Elaborado pelo autor

Como mostra o Gráfico 7-2, os valores ótimos para a minimização do MAPE no método de Holt-Winters com sazonalidade multiplicativa são:

- $\alpha = 1,00$;
- $\beta = 0,23$;

- $\gamma = 0,00$.

Para que seja possível uma interpretação dos valores dos parâmetros encontrados através da otimização do modelo e suas características será relembrado suas equações:

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

Tendência:
$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

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

Previsão:
$$F_{t+m} = (L_t + b_t m)S_{t-s+m}$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

L_t = nível de série no período t

b_t = tendência da série no período t

F_t = previsão de demanda no instante t

m = número de períodos a frente que deseja prever

α = constante de ponderação exponencial para a base (entre 0 e 1)

β = constante de ponderação para a tendência (entre 0 e 1)

γ = constante de ponderação para a sazonalidade (entre 0 e 1)

s = comprimento da sazonalidade

Como o $\alpha = 1,00$, a equação de nível pode ser simplificada para: $L_t = \frac{Y_t}{S_{t-s}}$, isso significa

que a componente de nível de previsão é extremamente sensível aos últimos valores da demanda real. Com $\beta = 0,23$, a equação de tendência é: $b_t = 0,23(L_t - L_{t-1}) + (0,77)b_{t-1}$. Isso significa que a componente b_t sofre pouca influência dos novos dados da série, dedicando maior peso à tendência do período anterior. Por fim, $\gamma = 0,00$ resulta na seguinte equação de sazonalidade: $S_t = S_{t-s}$, ou seja, a série não apresenta sensibilidade em relação ao histórico de sazonalidade, apresentando os mesmos valores que os calculados para a iniciação do modelo.

Além de encontrar os valores ótimos de α , β e γ , foi realizado uma análise de sensibilidade do MAPE para compreender o efeito que aqueles possuem sobre este. Nesta análise foi desconsiderado o efeito do γ devido ao valor ótimo encontrado ($\gamma = 0$).

Na Tabela 5-2 percebe-se que o MAPE encontra o seu ponto ótimo para α tendendo a um e β tendendo a zero, o que reforça os argumentos anteriores sobre a previsão ser sensível aos últimos valores de demanda real e aos últimos valores da tendência do período anterior.

Tabela 5-2- Análise de sensibilidade do MAPE para o método de Holt-Winters com sazonalidade multiplicativa para Tintos-A

		α										
		-	0,10	0,20	0,30	0,40	0,50	0,60	0,70	0,80	0,90	1,00
β	-	27%	29%	27%	26%	24%	22%	21%	20%	18%	17%	17%
	0,05	27%	30%	29%	27%	24%	23%	21%	20%	18%	18%	17%
	0,10	27%	30%	29%	27%	25%	23%	21%	19%	18%	18%	17%
	0,15	27%	31%	30%	28%	25%	23%	21%	19%	18%	18%	17%
	0,20	27%	31%	30%	28%	25%	23%	21%	19%	18%	17%	17%
	0,25	27%	31%	31%	28%	25%	23%	21%	19%	18%	17%	17%
	0,30	27%	32%	31%	28%	25%	22%	20%	19%	18%	17%	17%
	0,35	27%	32%	32%	28%	25%	22%	20%	18%	18%	17%	18%
	0,40	27%	32%	32%	28%	25%	22%	20%	18%	18%	18%	18%
	0,45	27%	32%	33%	28%	25%	22%	20%	19%	18%	19%	19%
	0,50	27%	33%	33%	28%	24%	22%	20%	19%	19%	19%	19%
	0,55	27%	33%	33%	28%	24%	21%	20%	20%	19%	20%	19%
	0,60	27%	33%	33%	28%	24%	22%	21%	20%	20%	20%	19%
	0,65	27%	34%	34%	28%	24%	22%	21%	20%	21%	20%	20%
	0,70	27%	34%	34%	28%	24%	22%	21%	20%	21%	21%	20%
	0,75	27%	35%	35%	28%	24%	23%	22%	21%	22%	21%	20%
	0,80	27%	35%	35%	28%	25%	23%	22%	22%	22%	21%	20%
	0,85	27%	36%	35%	28%	26%	24%	22%	22%	22%	21%	20%
	0,90	27%	36%	35%	28%	26%	24%	22%	23%	23%	22%	21%
	0,95	27%	37%	35%	28%	26%	24%	22%	23%	23%	22%	21%
	1,00	27%	37%	34%	29%	27%	25%	23%	24%	23%	22%	21%

Fonte: Elaborado pelo autor

Apesar do método de Holt-Winters apresentar o menor MAPE dentre os métodos aplicados; nota-se no Gráfico 5-2 que em alguns meses como janeiro e março de 2016, o resultado real e o previsto apresentam diferenças consideráveis.

Tal discrepância pode ser explicado devido ao método de Holt-Winters com tendência multiplicativa aumentar o tamanho das variações ao longo do tempo, o que pode resultar em grandes erros em determinados períodos.

Como pode-se observar no Gráfico 5-2, o mês de janeiro de 2016 apresentou uma queda na demanda, entretanto, a queda na previsão foi mais acentuada. Para janeiro de 2017, a previsão espera que está queda seja ainda mais brusca, fazendo com que a previsão retorne a patamares tão baixos quanto de anos anteriores, refutando a forte tendência de crescimento que a série apresenta.

Este resultado não deve ser aceito como fidedigno, sendo necessário um acompanhamento mensal da previsão. É aconselhável que se acompanhe a previsão com a utilização de um método alternativo, apenas para casos em que surgem diferenças muito bruscas entre os valores de meses consecutivos.

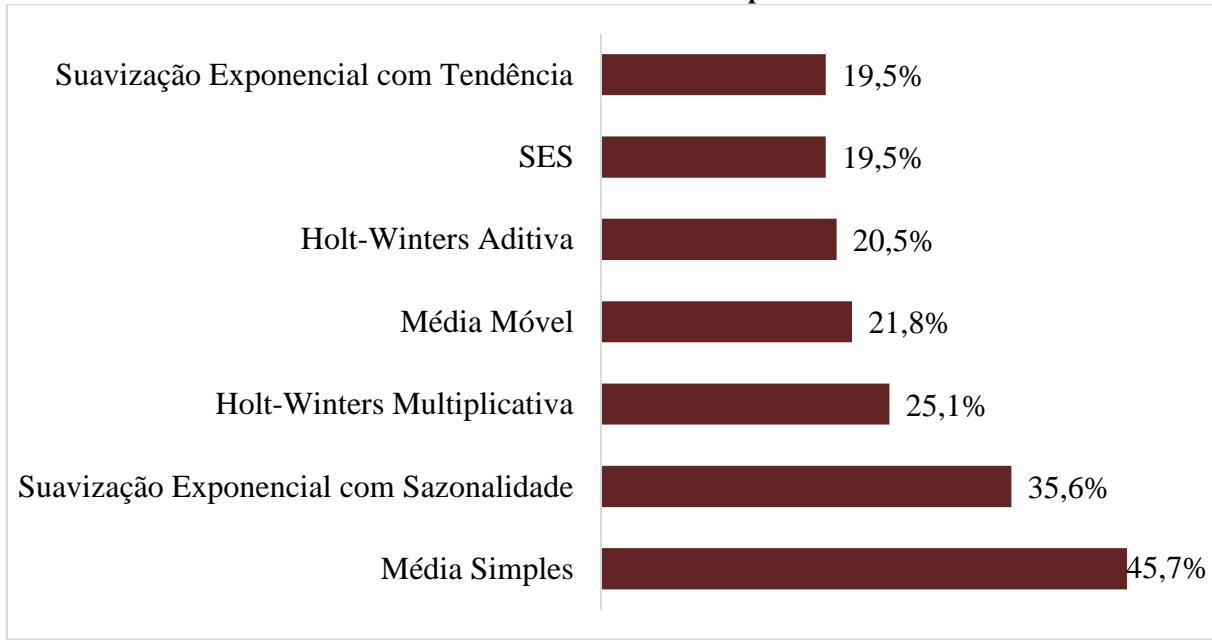
5.2 Brancos-A

Os métodos de suavização exponencial com tendência, SES e Holt-Winters com sazonalidade aditiva apresentaram melhores resultados do que o obtido pelo método atual de previsão utilizado na Vinhos.Co (média móvel simples com dois períodos) para os Brancos-B. Já os métodos de Holt-Winters multiplicativa, suavização exponencial com sazonalidade e média simples apresentam os piores resultados.

Os métodos estão listados a seguir do melhor para o pior:

- Suavização Exponencial com Tendência (Linear de Holt);
- SES;
- Holt-Winters Aditiva;
- Holt-Winters Multiplicativa;
- Média Móvel;
- Suavização Exponencial com Sazonalidade;
- Média Simples.

Os seus respectivos erros são apresentados no Gráfico 5-3:

Gráfico 5-3- MAPE dos Brancos-A por método

Fonte: Elaborado pelo autor

O Gráfico 5-3 mostra que os três piores métodos apresentam erros muito superiores aos encontrados pelos quatro melhores métodos, enquanto estes apresentam resultados muito próximos entre si.

Mais uma vez chega-se à conclusão que nem sempre métodos mais complexos apresentam melhores resultados. Neste caso, o método de suavização exponencial com tendência apresentou melhora de apenas 2,3 pontos percentuais em relação ao método de média móvel.

Tabela 5-3- Detalhes dos resultados obtidos para Brancos-A

Brancos-A	MSE	MAPE	Maior PE	n	α	β	γ
Média Simples	2,1E+08	45,7%	64,5%				
Média Móvel	3,7E+07	21,8%	78,2%	2			
SES	3,0E+07	19,5%	66,1%		0,53		
Suavização Exponencial com Tendência	3,2E+07	19,5%	64,1%		0,56	0,00	
Suavização Exponencial com Sazonalidade	1,3E+08	35,6%	90,1%		0,13		0,19
Holt-Winters Aditiva	8,2E+07	20,5%	81,4%		0,12	1,00	-
Holt-Winters Multiplicativa	3,5E+08	25,1%	118,8%		1,00	-	-

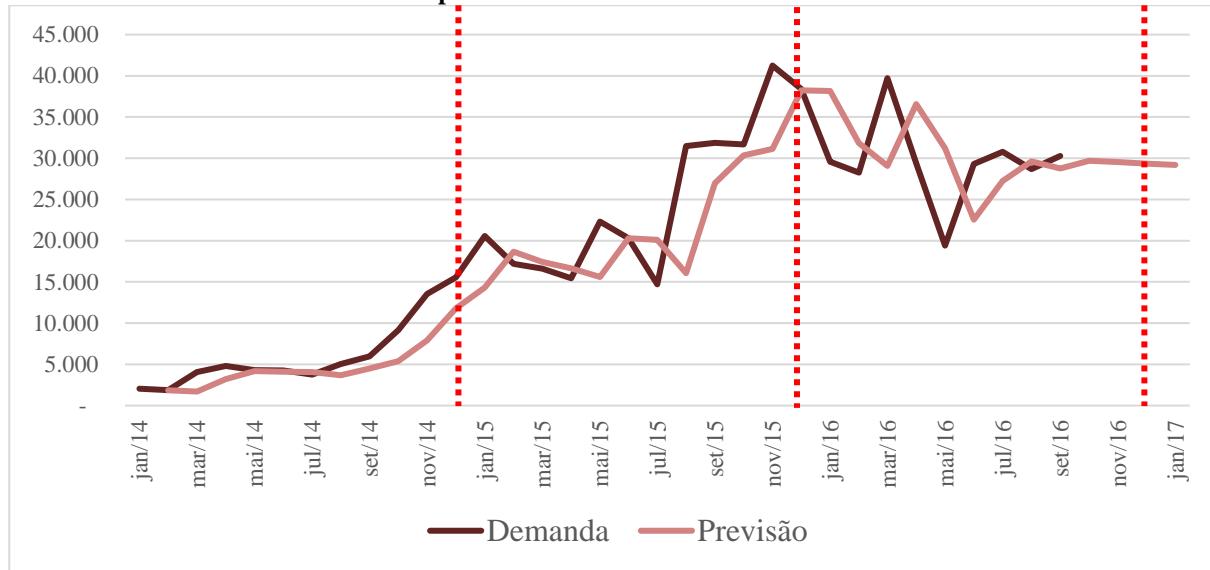
Fonte: Elaborado pelo autor

Na Tabela 5-3 pode-se ver que, apesar da diferença entre o MAPE do método de suavização exponencial com tendência e o SES se praticamente imperceptível, este apresenta um MSE ligeiramente menor. Entretanto, como o critério adotado para classificação para acurácia do modelo foi o MAPE, será utilizado o método de suavização exponencial com tendência.

Este método também apresenta maior $|PE|$ semelhante aos SES e à média simples, que apresenta justamente o pior MAPE.

Apesar da média simples apresentar valores para $|PE|$ semelhantes ao melhor método, a lentidão do método quando utilizado em séries com tendência resulta em um MAPE muito superior aos demais.

Gráfico 5-4- Resultado da previsão de Brancos-A utilizando o método linear de Holt



Fonte: Elaborado pelo autor

Serão relembradas as fórmulas do método linear de Holt para compreender as características do modelo e a curva de previsão do Gráfico 5-4:

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

$$b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

$$F_{t+m} = L_t + b_t m$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

L_t = nível de série no período t

b_t = tendência da série no período t

F_t = previsão de demanda no instante t

m = número de períodos a frente que deseja prever

α = constante de ponderação exponencial para a base (entre 0 e 1)

β = constante de ponderação para a tendência (entre 0 e 1)

Substituindo os valores de α e β encontrados na otimização do modelo, tem-se as seguintes equações:

$$L_t = 0,56 \times Y_t + 0,44 \times (L_{t-1} + b_{t-1})$$

$$b_t = b_{t-1}$$

$$F_{t+m} = L_t + b_t m$$

A equação de nível é influenciada de maneira praticamente igual pelo valor da demanda no mesmo instante e pela soma do nível com a tendência do instante anterior. A equação seguinte mostra que a série apresenta uma tendência constante.

No Gráfico 5-4, pode-se perceber que os valores previstos da demanda para os meses seguintes a setembro são praticamente constantes. Isso deve-se ao fato do valor de $b_1 = -170$ ser muito pequeno se comparado aos valores de níveis no período. Como o nível está em torno de 30 mil em setembro de 2016, a equação de previsão assume a seguinte forma: $F_{t+m} = 30000 - 170 \times m$, com m variando de um a quatro, que é o intervalo no qual se deseja realizar a previsão. O que resulta em uma previsão praticamente constante.

Dificilmente a demanda futura se comportará da maneira apresentada, mantendo a tendência de junho a setembro de permanecer constante. Uma correção na previsão deve ocorrer com a inserção de novos dados de demanda fora desse patamar nos meses seguintes.

Para compreender melhor o efeito do α e do β no modelo foi realizado um estudo de sensibilidade:

Tabela 5-4- Análise de sensibilidade do MAPE para o método linear de Holt para Brancos-A

		α										
		-	0,10	0,20	0,30	0,40	0,50	0,60	0,70	0,80	0,90	1
β	-	106%	43%	26%	23%	21%	20%	20%	20%	20%	20%	20%
	0,05	106%	33%	26%	22%	20%	20%	20%	21%	21%	21%	21%
	0,10	106%	33%	26%	22%	20%	21%	21%	22%	22%	22%	22%
	0,15	106%	34%	26%	22%	21%	22%	22%	23%	23%	23%	23%
	0,20	106%	34%	25%	22%	22%	23%	23%	23%	23%	23%	24%
	0,25	106%	33%	24%	22%	23%	23%	24%	24%	24%	24%	24%
	0,30	106%	32%	24%	23%	24%	24%	24%	24%	24%	24%	24%
	0,35	106%	31%	24%	24%	25%	25%	24%	24%	24%	24%	25%
	0,40	106%	30%	24%	25%	25%	25%	24%	24%	24%	25%	25%
	0,45	106%	29%	24%	25%	26%	25%	24%	24%	25%	25%	25%
	0,50	106%	28%	24%	26%	26%	25%	24%	24%	25%	25%	26%
	0,55	106%	27%	25%	27%	26%	25%	24%	25%	25%	26%	26%
	0,60	106%	26%	26%	27%	26%	25%	24%	25%	25%	26%	27%
	0,65	106%	26%	26%	28%	26%	25%	24%	25%	26%	27%	27%
	0,70	106%	25%	27%	28%	26%	25%	24%	25%	26%	27%	28%
	0,75	106%	25%	28%	28%	26%	25%	25%	25%	27%	28%	29%
	0,80	106%	25%	28%	28%	26%	24%	25%	26%	27%	28%	29%
	0,85	106%	25%	29%	28%	26%	24%	25%	26%	28%	29%	30%
	0,90	106%	26%	29%	28%	25%	25%	25%	27%	28%	30%	30%
	0,95	106%	26%	30%	28%	25%	25%	25%	27%	29%	30%	30%
	1,00	106%	26%	31%	28%	25%	25%	26%	28%	30%	31%	31%

Fonte: Elaborado pelo autor

Como mostra a Tabela 5-4, os menores valores de MAPE são alcançados para valores de α próximos de um e valores de β próximos de zero.

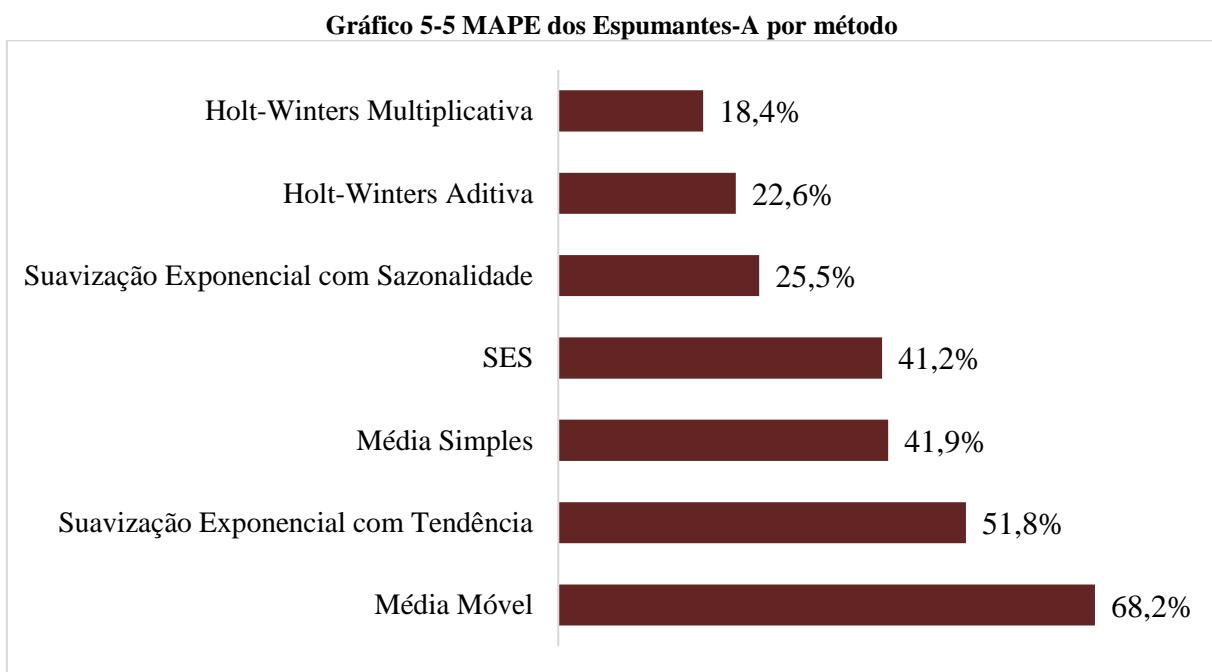
5.3 Espumantes-A

Os métodos de Holt-Winters com sazonalidade multiplicativa, Holt-Winters com sazonalidade aditiva e suavização exponencial com sazonalidade além de apresentarem os melhores resultados, ficaram próximos entre si. Enquanto o método atual utilizado pela companhia, média móvel, apresentou o pior resultado entre os métodos testados

Os métodos estão listados a seguir do melhor para o pior:

- Holt-Winters Multiplicativa;
- Holt-Winters Aditiva;
- Suavização Exponencial com Sazonalidade;
- SES;
- Média Simples;
- Suavização Exponencial com Tendência (Linear de Holt);
- Média Móvel.

Os seus respectivos erros são apresentados no Gráfico 5-5.



Fonte: Elaborado pelo autor

Os métodos de Holt-Winters Multiplicativa, Holt-Winters Aditiva e Suavização Exponencial com Sazonalidade apresentam resultados próximos com destaque para o primeiro. A média móvel, em contrapartida, apresenta resultado mais de três vezes pior do que o melhor método.

Os detalhes dos resultados obtidos são apresentados a seguir:

Tabela 5-5- Detalhes dos resultados obtidos para Espumantes-A

Espumantes-A	MSE	MAPE	Maior PE	n	α	β	γ
Média Simples	5,6E+07	41,9%	201,7%				
Média Móvel	6,7E+07	68,2%	565,2%	2			
SES	6,3E+07	41,2%	136,8%		0,02		
Suavização Exponencial com Tendência	9,0E+07	51,8%	284,3%		0,30	0,00	
Suavização Exponencial com Sazonalidade	2,3E+07	25,5%	177,6%		0,14		0,23
Holt-Winters Aditiva	1,1E+07	22,6%	172,6%		0,02	1,00	-
Holt-Winters Multiplicativa	4,3E+06	18,4%	142,8%		0,31	0,38	-

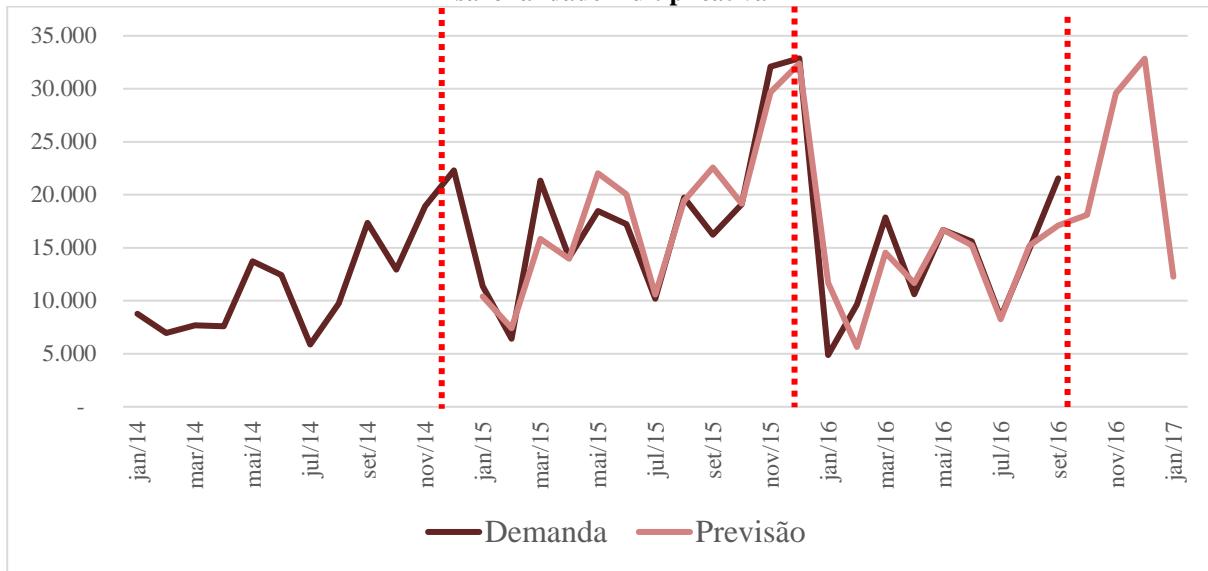
Fonte: Elaborado pelo autor

Na Tabela 5-5 pode ser observado que os métodos com sazonalidade apresentam os melhores resultados devido à característica dos Espumantes-A.

Tais métodos apresentam MAPE em torno de 50% menor do que os apresentados pelos demais métodos. O melhor método, Holt-Winters multiplicativa, apresenta um erro 73% menor

do que o apresentado pela maneira tradicional de previsão de demanda da companhia. Além disso, o método de média móvel apresenta 565,2% como o maior erro em um período observado, o que representa mais de duas vezes o segundo pior erro.

Gráfico 5-6- Resultado da previsão de Espumantes-A utilizando o método de Holt-Winters com sazonalidade multiplicativa



Fonte: Elaborado pelo autor

A sazonalidade com picos nos meses de dezembro e o aumento nos intervalos podem ser vistos de forma clara no Gráfico 5-6. Nota-se que a curva de previsão acompanha com poucos desvios a curva da demanda, com maior discrepância em janeiro de 2016, onde ocorre um erro de 142%. Este erro é pouco perceptível na análise visual do Gráfico 5-6, mas ocorre porque a demanda real apresentou um valor muito baixo em janeiro, fazendo com que uma pequena variação absoluta resultasse em uma grande variação percentual.

O MAPE deste método seria de apenas 12% caso fosse desconsiderado o erro ocorrido no mês de janeiro, consolidando ainda mais a escolha deste método para previsão de demanda dos Espumantes-A.

Como mostra a Tabela 5-5, os valores ótimos para a minimização do MAPE no método de Holt-Winters com sazonalidade multiplicativa são:

- $\alpha = 0,31$;
- $\beta = 0,38$;
- $\gamma = 0,00$.

Para analisar e interpretar os valores ótimos encontrados no método, será relembrado as equações:

$$\text{Nível: } L_t = \alpha \frac{Y_t}{S_{t-s}} + (1 - \alpha)(L_{t-1} + b_{t-1})$$

$$\text{Tendência: } b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1}$$

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

$$\text{Previsão: } F_{t+m} = (L_t + b_t m)S_{t-s+m}$$

Onde t = índice do período de tempo

Y_t = valor da demanda observada no instante t

L_t = nível de série no período t

b_t = tendência da série no período t

F_t = previsão de demanda no instante t

m = número de períodos a frente que deseja prever

α = constante de ponderação exponencial para a base (entre 0 e 1)

β = constante de ponderação para a tendência (entre 0 e 1)

γ = constante de ponderação para a sazonalidade (entre 0 e 1)

s = comprimento da sazonalidade

Substituindo os valores de α , β e γ nas equações, chega-se a:

$$\text{Nível: } L_t = 0,31 \times \frac{Y_t}{S_{t-s}} + 0,69 \times (L_{t-1} + b_{t-1})$$

$$\text{Tendência: } b_t = 0,38 \times (L_t - L_{t-1}) + 0,62 \times b_{t-1}$$

$$\text{Sazonalidade: } S_t = S_{t-s}$$

$$\text{Previsão: } F_{t+m} = (L_t + b_t m)S_{t-s+m}$$

Na curva de nível, observa-se que o modelo é mais de duas vezes mais sensível ao nível e a tendência anterior do que aos valores reais da demanda no instante t.

A curva de tendência apresenta comportamento parecido com a de nível. Apesar de ser sensível aos novos dados de níveis, acaba sofrendo maior influência pela tendência do período anterior.

Já a equação de sazonalidade mostra que tal característica não é influenciada por mudanças na série, permanecendo iguais ao longo do tempo.

Como o valor de $\gamma = 0$ foi encontrado como o valor ótimo para minimização do MAPE, foi realizado uma análise de sensibilidade para α e β apresentada na Tabela 5-6.

Tabela 5-6- Análise de sensibilidade do MAPE para o método de Holt-Winters com sazonalidade multiplicativa para Espumantes-A

		α										
		-	0,10	0,20	0,30	0,40	0,50	0,60	0,70	0,80	0,90	1,00
β	-	34%	27%	23%	21%	20%	20%	21%	21%	22%	22%	23%
	0,05	34%	26%	22%	20%	20%	20%	20%	21%	22%	22%	23%
	0,10	34%	25%	21%	20%	19%	19%	20%	21%	22%	23%	24%
	0,15	34%	24%	20%	19%	19%	19%	20%	21%	22%	23%	24%
	0,20	34%	24%	20%	19%	19%	20%	21%	21%	23%	24%	25%
	0,25	34%	23%	19%	19%	19%	20%	21%	22%	23%	24%	25%
	0,30	34%	22%	19%	19%	19%	20%	21%	22%	23%	25%	26%
	0,35	34%	22%	19%	18%	19%	20%	22%	23%	24%	25%	27%
	0,40	34%	21%	20%	18%	19%	21%	22%	23%	24%	26%	27%
	0,45	34%	21%	19%	18%	20%	21%	22%	23%	25%	27%	28%
	0,50	34%	21%	19%	18%	20%	21%	23%	24%	26%	27%	29%
	0,55	34%	21%	19%	19%	20%	22%	23%	24%	26%	28%	29%
	0,60	34%	21%	19%	19%	21%	22%	24%	25%	27%	29%	30%
	0,65	34%	21%	19%	19%	21%	23%	24%	25%	28%	29%	30%
	0,70	34%	22%	19%	20%	21%	23%	24%	26%	28%	30%	31%
	0,75	34%	22%	19%	20%	22%	23%	25%	26%	29%	31%	32%
	0,80	34%	22%	18%	20%	22%	24%	25%	27%	30%	31%	32%
	0,85	34%	22%	18%	21%	22%	24%	26%	28%	31%	32%	33%
	0,90	34%	22%	18%	21%	23%	25%	26%	28%	31%	33%	33%
	0,95	34%	22%	19%	21%	23%	25%	27%	29%	32%	33%	34%
	1,00	34%	22%	19%	21%	23%	25%	27%	30%	33%	34%	34%

Fonte: Elaborado pelo autor

Pode-se observar na Tabela 5-6 que o MAPE é otimizado para valores no intervalo de $0,20 \leq \alpha \leq 0,50$, mostrando que a equação de nível pode ser explicada utilizando a mesma lógica anterior. Ou seja, o nível é sensível ao valor da demanda apesar de ser mais impactado por alterações nos níveis e tendências do período anterior.

Já o β apresenta um intervalo maior de valores que mantem o MAPE próximo ao ótimo, dentro de uma faixa mínima de variação. Para intervalo de $0 \leq \beta \leq 1$, é possível manter o MAPE entre $18,4\% \leq MAPE \leq 22,2\%$.

Desta forma, é possível que, com a atualização de novos valores de demanda no modelo, a busca pelo menor MAPE possa mudar o impacto que a tendência no período t sofre pelo nível ou pela tendência do período anterior.

6 CONCLUSÃO

A grande competitividade existente no mercado atual faz com que as empresas busquem constantemente por vantagens competitivas capazes de diferenciá-las das demais. Em empresas varejistas, o domínio da cadeia de abastecimentos é um fator importante de diferenciação.

Neste sentido foi identificado dois principais problemas: A ruptura de estoque de produtos chave que pode resultar na perda de vendas, clientes, contas e até mesmo na aquisição de novos clientes, e o alto nível de inventário resultado de uma tentativa de evitar o primeiro problema ao longo dos anos.

A causa dos problemas acima encontra-se na falta de métodos de previsão de demanda para a tomada de decisão ao longo da cadeia de abastecimentos. Com isso, o trabalho se propôs a aplicar diferentes métodos de previsão de demanda para as principais famílias de produtos da empresa.

O resultado alcançado foi consideravelmente melhor do que o apresentado pela Vinhos.Co, com isso foi possível a implementação do modelo desenvolvido na empresa, devido à sua simplicidade e facilidade para utilização.

Para trabalhos futuros, ou para a continuidade do presente trabalho, o autor sugere a implementação de métodos qualitativos, envolvendo as áreas comerciais e o *marketing* da empresa. Desta maneira, será possível a incorporação de outras variáveis, de modo a refinar as soluções e aumentar a acurácia do modelo.

REFERÊNCIAS

- ALMEIDA, A. N., BRAGAGNOLO, C., & CHAGAS, A. L. **A Demanda por Vinho no Brasil:** elasticidades no consumo das famílias e determinantes da importação. Revista de Economia e Sociologia Rural, 433-454, 2015.
- ARMSTRONG, J. S. **Principles of forecasting:** A Handbook for Researchers and Practitioners. Boston: Kluwer Academic, 2001.
- BAILS, G. D. & PEPPERS,L.C. **Business Fluctuations:** Forecasting Techniques and Applications. New Jersey: Prentice-Hall, 1982.
- BALLOU, R. H. **Gerenciamento da Cadeia de Suprimentos:** planejamento, organização e logística empresarial. 4^a ed. Porto Alegre: Bookman, 2001.
- DIEBOLD, F. X. **Elements of Forecasting.** Ohio: South - Western College Publishing, 1998.
- HAWESCO. **Hawesco Holding Annual Report,** 2015.
- IBRAVIN. **Estudo do Mercado Brasileiro de Vinhos Tranquilos e Espumantes,** 2008.
- IBRAVIN. **Faturamento do setor vinícola,** 2013.
- IBRAVIN. **Importações brasileiras de vinhos e espumantes,** 2016.
- MAJESTIC. **Annual Report,** 2016.
- MAKRIDAKIS, S. C. **Forecasting Methods and Applications.** New York: John Wiley & Sons, 1998.
- MIKHAIL, E., & ACKERMAN, F. **Observations ans Least Squares.** Washington, D.C.: University Press of America, 1976.
- ROTHE, J. T. **Effectiveness of Sales Forecasting Methods.** Industrial Marketing Management. v. 7, p. 114-118, 1978.
- WHEELWRIGHT,S. C., & MAKRIDAKIS,S. **Forecasting Methods for Management.** New York: John Wiley & Sons, 1985.