

UNIVERSIDADE ESTADUAL DE MARINGÁ
CENTRO DE TECNOLOGIA
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PRODUÇÃO

LORENA MAZIA ENAMI

**Previsão de Séries Temporais Sazonais no Controle de Estoque de
Medicamentos Oncológicos de Alto Custo**

Maringá
2021

LORENA MAZIA ENAMI

Previsão de Séries Temporais Sazonais no Controle de Estoque de Medicamentos Oncológicos de Alto Custo

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Departamento de Engenharia de Produção, Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção.

Área de concentração: Engenharia de Produção

Orientadora: Profa. Dra. Daniele C. Tita Granzotto
Coorientadora: Profa. Dra. Gislaine Camila Lapasini Leal

Maringá
2021

Dados Internacionais de Catalogação na Publicação (CIP)
(Biblioteca Central - UEM, Maringá, PR, Brasil)

E56p Enami, Lorena Mazia
Previsão de Séries Temporais Sanzonais no controle de estoque de medicamentos oncológicos de alto custo / Lorena Mazia Enami. -- Maringá, 2021.
73 f. : il., color., figs., tabs.

Orientador(a): Profa. Dra. Daniele Cristina Tita Granzotto.
Co-orientador(a): Profa. Dra. Gislaine Camila Lapasini Leal.

Dissertação (mestrado) - Universidade Estadual de Maringá, Centro de Tecnologia, Departamento de Engenharia de Produção, Programa de Pós-Graduação em Engenharia de Produção - Área de Concentração: Engenharia de Produção, 2021.

1. Suavização exponencial. 2. Previsão. 3. Cuidado à saúde. 4. Séries temporais - Estatística. I. Granzotto, Daniele Cristina Tita, orient. II. Leal, Gislaine Camila Lapasini, coorient. III. Universidade Estadual de Maringá. Centro de Tecnologia. Departamento de Engenharia de Produção. Programa de Pós-Graduação em Engenharia de Produção - Área de Concentração: Engenharia de Produção. IV. Título.

CDD 21.ed. 658.7

FOLHA DE APROVAÇÃO

LORENA MAZIA ENAMI

Previsão de Séries Temporais Sazonais no Controle de Estoque de Medicamentos Oncológicos de Alto Custo

Dissertação apresentada ao Programa de Pós-Graduação em Engenharia de Produção do Departamento de Engenharia de Produção, Centro de Tecnologia da Universidade Estadual de Maringá, como requisito parcial para obtenção do título de Mestre em Engenharia de Produção pela Banca Examinadora composta pelos membros:

BANCA EXAMINADORA

Profa. Dra. Daniele Cristina Tita Granzotto (*in memoriam*)
Universidade Estadual de Maringá – DES/UEM



Profa. Dra. Gislaine Camila Lapasini Leal
Universidade Estadual de Maringá – DEP/UEM



Prof. Dr. Danilo Hisano Barbosa
Universidade Estadual de Maringá – DEP/UEM



Prof. Dr. Vanderly Janeiro
Universidade Estadual de Maringá – DES/UEM

Aprovada em: 25 de fevereiro de 2021.

Local da defesa: <https://meet.google.com/mge-ubtv-cat>.

Dedico esse trabalho à memória da minha querida orientadora, Daniele Cristina Tita Granzotto. Sem ela, com certeza, esse trabalho não seria desenvolvido com tamanha maestria e alegria.

AGRADECIMENTOS

Aos meus pais Wanderlei e Cida e aos meus irmãos, Marcelo e Rodrigo pelo apoio durante a realização da pesquisa. Em especial, ao último que me guiou e incentivou na academia.

À minhas queridas sobrinhas Elise e Lauren por embelezarem os momentos difíceis durante esse processo.

A todos meus amigos, tanto do programa de pós graduação da Universidade Estadual de Maringá como externamente a ela, que me acompanharam nessa caminhada. Em especial, ao Marco Aurelio Valles Leal por seu apoio e conhecimento.

Aos funcionários e docentes da Universidade Estadual de Maringá.

Aos professores Franciele, Cid, Danilo e Vanderly pela participação em bancas com contribuições benéficas.

À minha orientadora, Professora Dra. Daniele Cristina Tita Granzotto por me guiar em cada etapa desse trabalho com paciência e sabedoria, tornando o caminho agradável e alegre.

À minha coorientadora, Professora Dra. Gislaine Camila L. Leal por suas contribuições e paciência.

A minha segunda família, Bruno, Larissa, Linhares, Marco e Matheus.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES), por seu financiamento.

*“Essentially,
all models are wrong,
but some are useful.”*

(George E. P. Box)

Previsão de Séries Temporais Sazonais no Controle de Estoque de Medicamentos Oncológicos de Alto Custo

RESUMO

Desejada por cada empresa ao redor do mundo, a redução de custos em diversos campos não é apenas uma meta, mas uma obrigação. A pressão externa enfrentada pelos sistemas de saúde em termos de redução de custos, muitas vezes, leva a ações sobre os medicamentos, principalmente sobre seu estoque. Previsões incorretas podem ter consequências trágicas no tratamento dos pacientes ou altos custos operacionais, devido ao seu sub e superdimensionamento. Do ponto de vista prático, pode haver dinheiro preso, mas não menos medicamentos do que o necessário. Pensando em reduzir o valor monetário comprometido e não deixar de atender a demanda, este trabalho é um estudo de caso de controle de estoque de medicamentos oncológicos em um hospital de médio porte. Especificamente, é proposto a adição de estoque de segurança ao modelo paramétrico Aditivo de Holt-Winter para prever o consumo do medicamento de maior impacto financeiro entre 2015 e 2019 em um hospital do Estado do Paraná, Brasil. Indicadores como giro de estoque e nível de serviço também foram utilizados como forma de validação do modelo, legitimando a interface entre previsão de demanda e gestão de estoque, o que muitas vezes é esquecido na literatura. Considerando um medicamento com um custo de 4,5 vezes o valor do salário mínimo brasileiro para cada dose, este trabalho tem grande impacto prático.

Palavras-chave: Suavização exponencial, Séries, Previsão, Cuidado à saúde.

Seasonal time series forecasting in the inventory control of high-cost drugs used in the treatment of cancer

ABSTRACT

Desired by each company around the world, the cost reduction is in several fields not only a target but an obligation. The external pressure faced by health systems in terms of cost reduction, often leads to actions on medicines, specially on its inventory. Incorrect forecasts can have tragic consequences in the treatment of patients or high operating costs, due to their under and over-dimensioning. From a practical point of view it can have cash trapped but never less drugs than you need. Thinking of reducing the cash trapped and not fail to meet the demand, this work is a case-study of the inventory control in an oncology sector of the medium size hospital. Specifically, we propose a correction in the forecast of the parametric Holt-Winter's Additive model to predict the consumption of the medicine with the greatest financial impact between 2015 and 2019 in a hospital in the State of Paraná, Brazil. Indicators such as inventory turnover and service level were also used as a way of model validation, legitimizing the interface between demand forecasting and inventory management, which is often overlooked in the literature. Considering a drug with a cost of 4.5 times the value of the Brazilian minimum wage for each dose, this work has a great practical impact.

Keywords: *Exponential smooth, series, forecast, health care.*

LISTA DE FIGURAS

2.1	Municípios da 15 ^a Regional da Saúde.	19
2.2	Fluxograma de pesquisa	20
2.3	Custo de estoque dos medicamentos de acordo com seu tipo	24
2.4	Fluxograma do processo ressuprimento	26
3.1	Consumo mensal por medicamento	31
3.2	Consumo mensal do medicamento 2 considerando uma diferenciação.	34
3.3	Ciclo iterativo de escolha da estrutura do modelo.	35
4.1	Valor dos Medicamentos Oncológicos em Estoque	44
4.2	Consumo médio mensal ao longo dos anos e média mensal global do consumo do Medicamento	45
4.3	Estoque e consumo mensal de Medicamentos	45
4.4	Função autocorrelação	47
4.5	Valores residuais do modelo AR(2)	48
4.6	Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado AR(2) comparada com a demanda observada.	50
4.7	Análise dos resíduos do modelo ajustado de Holt-Winters Aditivo.	52

4.8	Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado Holt-Winters Aditivo comparada com a demanda observada.	53
4.9	Análise dos resíduos do modelo ajustado de Holt-Winters multiplicativo.	54
4.10	Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado Holt-Winters Multiplicativo comparado com a demanda observada.	55
4.11	Gráfico de sazonalidade.	56
4.12	Série de consumo prevista pelos modelos.	57
4.13	Efeito do Estoque de Segurança (HWAes).	60
4.14	Estoques iniciais	63

LISTA DE TABELAS

2.1	Demonstração descritiva dos dados	23
4.1	Grupos de Medicamentos	44
4.2	Estimativas dos parâmetros do modelo de AR(2)	48
4.3	Critérios de seleção de modelo σ^2 , Akaike (AIC) e log verossimilhança.	48
4.4	Testes de Resíduos - ruídos brancos	49
4.5	Parâmetros sazonais iniciais (s)	51
4.6	Testes de resíduos - ruídos brancos	51
4.7	Parâmetros sazonais iniciais (s)	54
4.8	Testes de resíduos - ruídos brancos	54
4.9	Análise da acurácia dos modelos estimados.	56
4.10	Previsões de consumo para os modelos Box & Jenkins e Holt-Winters aditivo.	57
4.11	Impacto do estoque de segurança ao modelo de Holt-Winters aditivo.	60
4.12	Indicadores de desempenho para a gestão de estoque.	61

1	Introdução	14
1.1	Objetivos do trabalho	16
1.2	Estrutura do trabalho	17
2	Apresentação do problema	18
2.1	Metodologia da pesquisa	19
2.1.1	Planejamento da Pesquisa	20
2.1.2	Coleta de dados	21
2.1.3	Análise dos dados	23
2.2	Estudo de Caso	23
3	Modelos de Séries Temporais	29
3.1	Contextualização	30
3.2	Principais modelos univariados	32
3.2.1	Modelos de Box & Jenkins	34
3.2.2	Modelo de suavização ou amortecimento exponencial	40

4	Resultados	43
4.1	Modelagem e avaliação do ajuste dos modelos	46
4.2	Ajuste do modelo de Box & Jenkins	47
4.3	Ajuste dos modelos de Holt-Winters	50
4.3.1	Ajuste do modelo de Holt-Winters aditivo	50
4.3.2	Ajuste do modelo de Holt-Winters multiplicativo	53
4.4	Comparação dos modelos	55
4.5	Análise de Estoque	58
5	Conclusão e Perspectivas Futuras	65
6	Agradecimentos	67

CAPÍTULO 1

INTRODUÇÃO

Os serviços prestados pelas organizações na área da saúde podem afetar diretamente a expectativa de vida populacional, sendo que as suas políticas de assistência farmacêutica desempenham papel crucial neste processo. Um gargalo encontrado na área de assistência farmacológica é a necessidade de tratamentos específicos para determinada área terapêutica, Nikolopoulos et al. (2016). Segundo Litvak e Long (2000), as singularidades terapêuticas geram estresses no sistema dada a incerteza das demandas medicamentosas à curto e longo prazo. Aghababaei et al. (2019) complementam expondo que a administração dessas incertezas proporcionam a maximização dos ganhos com saúde, e conseqüente, minimização dos custos.

A todo momento decisões de alocação de recursos devem ser tomadas mesmo diante de incertezas, apenas para garantir o atendimento dos serviços, sem conseguir estimar de forma adequada o número de indivíduos que precisarão destes cuidados no tempo determinado (por exemplo dentro de um mês). Em geral, estas previsões de demanda são realizadas pautadas no empirismo e na experiência de gestores de áreas totalmente antagônicas às da estatística, matemática ou engenharia.

A carência de previsões de demanda precisas, que permitam a antecipação das necessidades desses indivíduos e auxiliem os tomadores de decisões, é imensa. Estes gestores precisam saber como gerenciar recursos e comprar suprimentos ao longo do tempo sem nenhum respaldo metodológico para tal, Jalalpour et al. (2015). Gerenciar as compras é crucial e indispensável para o êxito da assistência farmacêutica, visto que,

os gastos com saúde estão aumentando em taxas exponenciais se comparada ao resto da economia, Goozner (2015). Garcia et al. (2020) confirma, ao, em sua revisão, identificar o aumento dos gastos farmacêuticos nos últimos anos dado a maior longevidade da população, a prevalência de doenças crônicas e aos custos de novos medicamentos para tratamentos de doenças específicas como o câncer. Assim, os gastos com saúde são constituídos, principalmente, por medicamentos, Wang et al. (2015); McConnell et al. (2017); Haslam et al. (2019).

Tendo a ciência de que uma estimativa de demanda futura é fundamental, sendo capaz de minimizar os custos de estoque, este trabalho tem como objetivo o estudo de modelos com base em padrões históricos nos dados, ver por exemplo Sagaert et al. (2018). Atualmente, os métodos controlados por dados no processo de previsão incluem, especialmente, modelos de séries temporais, foco deste estudo, Jalalpour et al. (2015).

Esses modelos são versáteis e podem ter dois métodos de aplicação, que pode ser de maneira individual (por série) ou agregada (*cluster*). A seleção individual refere-se separadamente à seleção de um modelo de previsão “ideal”. Essa estratégia tem a vantagem de caracterizar recursos específicos de séries temporais, como estacionariedade, tendência, sazonalidade e volatilidade, que aparecem em cada série individualmente, Wang e Petropoulos (2016).

Modelos de séries temporais são de suma importância em todas as ciências aplicadas para cada disciplina com suas próprias características, Tratar et al. (2016), e têm sido selecionados para o gerenciamento de doenças e gastos, devido à sua habilidade para prever e maior aplicabilidade do que técnicas não temporais, Wang et al. (2015). Os métodos autorregressivo integrado de médias móveis (ARIMA) e suavização exponencial são ferramentas poderosas para otimizar séries temporais, prevendo a demanda futura e a redução dos custos de estoque. Ambos os métodos serão abordados nesta pesquisa e a razão para popularidade e utilização dessas métricas é a facilidade de interpretação dos resultados.

Na contramão da simplicidade, por se tratarem de métodos paramétricos, requerem o uso de computação e conhecimento especializado para sua implementação. Além da modelagem, o diagnóstico dos modelos propostos são realizados pelo exame dos resíduos, obtendo com isso inferências confiáveis, Jalalpour et al. (2015); Nikolopoulos et al. (2016); Wang e Petropoulos (2016).

De forma resumida, neste trabalho buscamos melhorar a eficiência das previsões em uma organização prestadora de serviços de saúde no Brasil, aplicando metodologias estatísticas aos dados de consumo de medicamentos. Para isso, várias técnicas de previsão conhecidas (naive, de médias móveis, de amortecimento exponencial e Box & Jenkins) foram aplicadas aos dados reais, correspondentes ao consumo de pacientes da região denominada como 15^a regional de saúde (RG), responsável pela população de 10.279.545 habitantes.

Assim, este trabalho objetiva responder: Como podemos promover a demanda correta para o consumo de medicamentos nas organizações prestadoras de serviços de saúde, mantendo níveis de serviço adequados e reduzindo os custos de estoque?

1.1 Objetivos do trabalho

Este trabalho tem como objetivo principal identificar, analisar e discutir as adequações dos modelos de séries temporais naive, de médias móveis, de amortecimento exponencial e Box & Jenkins na previsão de demanda de medicamentos farmacêuticos. Ao final, o resultado das previsões desses modelos pode ser comparados a dados reais para validar ou não sua utilização na gestão de estoques farmacêuticos.

Para isso, é necessário descrever estatisticamente as séries originais, testar a adaptação dos modelos de séries temporais mencionados acima, á um nível aceitável de confiabilidade, exibir as previsões futuras, e analisar a viabilidade proposta desse trabalho.

Outros objetivos menores também fazem parte desta pesquisa:

- Ajustar modelos parcimoniosos, visando a simplicidade e acurácia sempre;
- Descrever os resultados de forma que o entendimento de pessoas leigas da área estatística consigam interpretar e replicar esta pesquisa;
- Mitigar erros de super e sub estimação de estoque e naturalmente reduzir gastos desnecessários e custos extras.

1.2 Estrutura do trabalho

Para um melhor entendimento deste trabalho o dividimos em 5 Capítulos. O primeiro traz de forma breve uma introdução ao problema bem como os objetivos desta pesquisa, guiando o leitor e evidenciando as complicações interligadas entre a gestão de estoque e a previsão de demanda.

No Capítulo 2 apresentamos as etapas de estudo de caso sugeridas por Miguel (2007). Um enfoque é dado para as etapas de planejamento de pesquisa e coleta de dados. Posteriormente, a caracterização do problema é apresentada pontuando possíveis causas para o problema prático. Já no Capítulo 3 exploramos os conceitos fundamentais de séries temporais. Uma contextualização sobre previsão de demanda é realizada, com foco nos modelos quantitativos de séries temporais, em especial os univariados: naive, de médias móveis, de amortecimento exponencial e Box & Jenkins.

Os resultados das análises feitas com o uso do *software* livre R são apresentadas no Capítulo 4. A função FAC e FACP, dos dados coletados em campo, são apresentadas e, na sequência, os gráficos e tabelas pertinente aos diferentes modelos de previsão são fragmentados em subseções referentes ao ajuste do modelo de Box & Jenkins, ajuste dos modelos de Holt-Winters e a comparação entre ambos, respectivamente.

As considerações finais e perspectivas futuras são apresentadas no Capítulo 5 e subsequente a este capítulo, apresentamos as principais referências que guiaram esta pesquisa.

CAPÍTULO 2

APRESENTAÇÃO DO PROBLEMA

A globalização faz com que as empresas busquem constantemente maior competitividade no mercado. Neste cenário, hospitais e sistemas de saúde são forçados a estudar e executar iniciativas de contenção de custos em suas organizações, McConnell et al. (2017).

Neste Capítulo apresentamos tanto a metodologia de pesquisa, quanto a caracterização do processo organizacional de uma empresa, prestadora de serviços para a área da saúde, atuante a nível nacional e que não será identificada nesse trabalho (por questões éticas e à pedido da própria empresa). A divisão do capítulo se dá pois o modo como conduzimos o estudo é importante para sua confiabilidade, validade e reprodutibilidade, e o processo organizacional pode ser uma das causas dos custos operacionais elevados, conforme apontado por McConnell et al. (2017).

Ademais, os dados fornecidos representam a quantidade de medicamento do setor de oncologia, que atende aos municípios da grande Maringá. Dessarte, os valores de consumo abrangem usuários de trinta municípios da 15ª Regional de Saúde (RS) como mostra a Figura 2.1.

Figura 2.1. Municípios da 15ª Regional da Saúde.

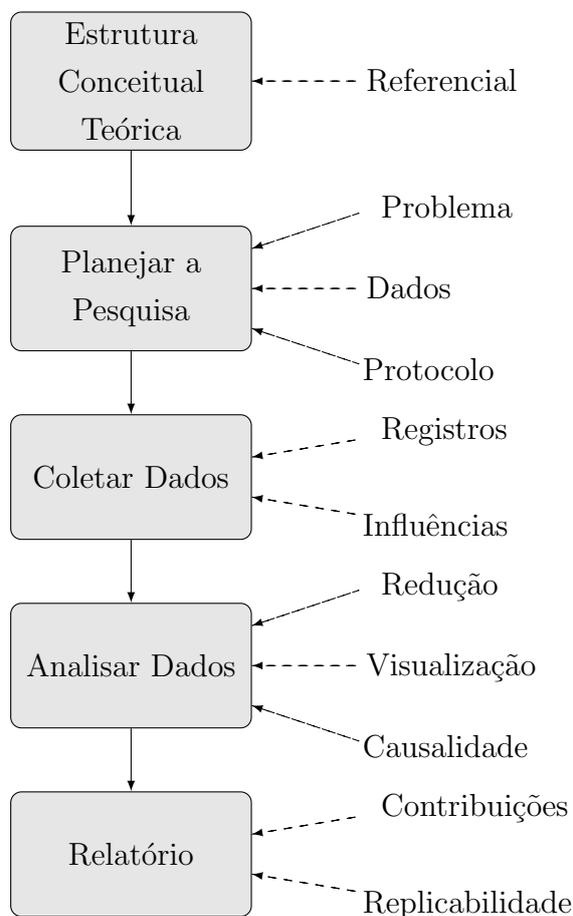


Fonte: Secretaria da Saúde do Estado do Paraná

2.1 Metodologia da pesquisa

Nessa pesquisa apresentamos um estudo de caso, ou seja, a análise de um fenômeno atual em seu ambiente natural com limites imprecisos, Yin (2015). O estudo de caso alveja a compreensão explanada dos objetos de pesquisa por intermédio de múltiplos instrumentos de coleta de dados, Berto e Nakano (2014).

Para maior entendimento, delineamos um fluxograma de pesquisa à partir dos preceitos apresentados por Miguel (2007), exposto na Figura 2.2. Basicamente, o autor caracteriza o estudo científico em seis etapas: definir uma estrutura conceitual teórica, planejar o caso, conduzir o teste piloto, coletar os dados, analisar os dados e gerar relatório. Aqui, consideraremos apenas cinco etapas, uma vez que a fase de teste tem como objetivo averiguar o protocolo de pesquisa e pode ser inserida na fase de planejamento.

Figura 2.2. Fluxograma de pesquisa

Fonte: Autor (2020)

A fim de tornar este trabalho viável, cada uma destas cinco etapas foram seguidas e são pontuadas a seguir.

2.1.1 Planejamento da Pesquisa

Planejar a pesquisa consiste, inicialmente, em determinar a quantidade de casos, único ou múltiplos, mediante critérios significantes e justificáveis - ver por exemplo Yin (2015). Aqui, lidamos com um estudo de caso único que proporciona uma investigação minuciosa do problema, sendo restrito quanto à generalização dos resultados em âmbito de um único evento, Miguel (2007).

Frequentemente longitudinais, este tipo de estudo, único, trabalha com séries de dados históricos, Yin (2015). Nesta pesquisa, conceitos de estatística serão utili-

zados na avaliação dos dados históricos de medicamentos, em uma única empresa de prestação de serviços de saúde. Os medicamentos foram selecionados conforme sua representatividade em termos de custo de estoque, contribuindo para grandes despesas operacionais e comprometendo os resultados financeiros, Kourentzes et al. (2019).

Prodanov e de Freitas (2013) demonstram a validade da pesquisa quantitativa em estudos de caso único, pressupondo que tudo pode ser quantificável com a aplicação de técnicas estatísticas. No entanto, uma outra preocupação nessa categoria de estudos diz respeito à qualidade/confiabilidade dos dados.

Os estoques por demanda de medicamentos impactam diretamente no tratamento, e portanto na vida de muitos usuários daquele sistema de saúde. Logo, a acuracidade destes estoques foi medida por meio de auditorias de verificação manual, conforme sugerido por Wang et al. (2010), realizadas periodicamente para demonstrar a confiabilidade dos dados, as quais certificam erros inferiores a 1%. . Por sua complexidade e impacto, as bases de dados, pertencentes a área da saúde, são confiáveis.

Além da acurácia dos dados devido à sua natureza, o acesso restrito a estas informações incute confiabilidade extra já que a fonte de informações consiste em dados históricos, dos módulos do *enterprise resource planning* (ERP) da empresa, manuseado apenas por conhecedores de suas regras de negócio.

Todas as informações cedidas pela empresa foram codificadas de forma a descharacterizar o usuário, e também para facilitar o manuseio em *softwares* estatísticos livres, como por exemplo o R, R Core Team (2020).

2.1.2 Coleta de dados

Coletar dados para um estudo de caso foi, em um passado não muito distante, tarefa massante e demasiadamente longa, Prodanov e de Freitas (2013). Em tempos de *Big Data* e *Data Science* e com os avanços tecnológicos a coleta, organização, apresentação e compartilhamento de dados se tornou acessível e, dependendo da técnica empregada, simples, Ledford e Gast (2018). Além do que, nos dias atuais qualquer instituição possui sistemas de armazenamento e gerenciamento de dados.

Como já mencionado, as principais informações foram retirados do ERP, que registra todas as movimentações de estoque. Materiais e medicamentos hospitalares

são agrupados por classe conforme compatibilidade quanto a sua finalidade. De mesmo modo, o sistema fornece o custo total de estoque de cada classe de medicamentos, o que possibilitou o conhecimento da representatividade monetária de cada um. A mais onerosa ao sistema, oncológica (92%), é objeto de estudo deste trabalho.

O tipo movimentação de estoque mais importante para esta pesquisa é a dispensação de medicamentos por prescrição médica. Assim, setamos a data inicial das prescrições dos medicamentos no sistema, e consideramos para este estudo apenas movimentações com datas iniciais posteriores à janeiro de 2015. Foram retornadas dados de 163 medicamentos.

A análise do banco de dados foi realizada para a retirada de informações não relevantes, e limpeza dos dados, relacionadas por exemplo ao número das notas fiscais e outros processos. Outro ponto a ser destacado é a data de movimentação, fator fundamental para que o consumo mensal total de medicamentos fosse extraído. Informações pertinente aos custos foram utilizadas para priorização dos medicamentos e identificação de uma possível mitigação de prejuízos econômicos, sem alteração da qualidade de fornecimento.

Os custos considerados pelo sistema, usados como base para esta investigação, são essencialmente os valores pagos aos fornecedores, ignorando despesas adicionais com a manutenção do espaço, armazenagem, logística, pedidos e ajustes gerais. Apesar de não considerarmos os impactos de sua armazenagem, os custos são intrínsecos pois os medicamentos oncológicos além de serem os que mais oneram em termos de valor de compra, são também os medicamentos que possuem maior valor de manutenção pois precisam ser cuidadosamente refrigerados.

O medicamento oncológico com maior representatividade econômica e massiva utilização foi selecionado para essa pesquisa. Para este medicamento, após o tratamento na base de dados, os consumos mensais foram identificados - caracterizando uma série de custos ao longo do tempo. A mesma está enquadrada no período de tempo de janeiro de 2015 à maio de 2019, totalizando 53 observações.

A série é equiespaçada e discreta, ou seja, existe apenas um valor por mês advindo de um processo de contagem. As variáveis exógenas, que alimentarão um possível modelo, são os dados de consumo, aqui chamados de demanda, e as covariáveis: meses, anos, tipo de medicamento e valores.

2.1.3 Análise dos dados

O quarto item apontado na Figura 2.2 trata-se da análise dos dados, iniciada após a coleta e limpeza da base de informação. Neste ponto devemos considerar que os dados cedidos pela empresa já foram validados e reduzidos, armazenando para a análise somente o que é essencial para a pesquisa, Miguel (2007).

Um painel demonstrativo dos dados tratados é disposto na Tabela 2.1. A comparação das quantidade iniciais de medicamentos em estoque com o total consumido no mês pode ser feito apoiado nos dados da tabela e um superdimensionamento fica evidente.

Tabela 2.1. Demonstração descritiva dos dados

Mês	Ano	Est. Inicial	Consumo	Compra	Est. Final
<i>Jan</i>	2015	20.75	30.00	20.00	10.75
<i>Fev</i>	2016	27.92	38.26	30.00	19.66
<i>Mar</i>	2017	79.28	53.25	45.00	71.03

Fonte: Autor (2020)

Após análise inicial dos dados, prosseguimos com uma análise estatística completa, desde a descrição até modelagem e possível previsão de demandas. Estes resultados são apresentados à frente, no Capítulo 4.

2.2 Estudo de Caso

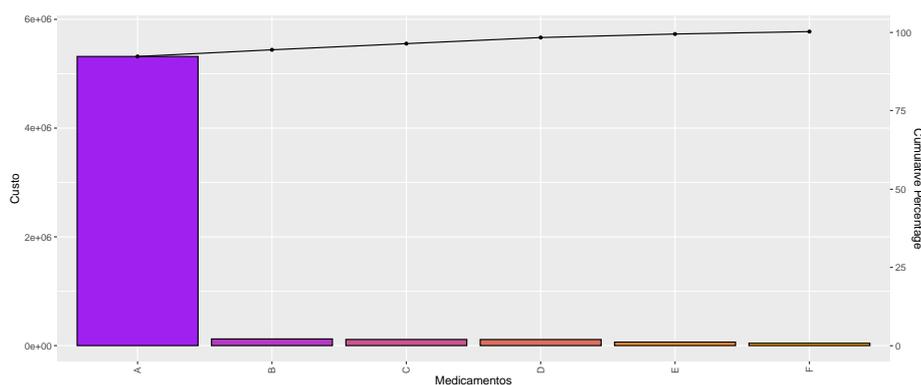
Os sistemas de saúde enfrentam a pressão externa para a implantação de iniciativas de redução de custos, que podem ser em âmbito de estratégias operacionais ou clínicas. Usualmente, para ambientes de cuidados agudos, essas estratégias de redução são aplicadas nas diversas atividades relacionadas ao setor farmacêutico McConnell et al. (2017).

O estudo de caso foi realizado em uma prestadora de serviços de tratamento a saúde, caracterizada como uma empresa de grande porte, que oferta dentre vários recursos terapêuticos o acompanhamento oncológico. Nela a gestão farmacêutica é responsável pela compra de medicamentos, materiais hospitalares, alimentos para dieta e materiais administrativos, assim como o gerenciamento, dispensação, manipulação e descartes dos mesmos.

Com o intuito de reduzir custos operacionais, consideramos a importância do item em estoque de acordo com seu custo de aquisição, ou seja, quanto maior o valor monetário do medicamento em estoque mais importante ele é tido. A Figura 2.3 representa os valores das classes de materiais e medicamentos em estoque e suas representatividades no todo, destacando os medicamentos oncológicos (Medicamento A). Conseqüentemente, eles são considerados medicamentos de alto custo.

No Brasil não há uma definição para medicamentos de alto custo, porém uma proposta é considerar aqueles cujos valores estejam acima do valor do salário mínimo Souza et al. (2010). A terminologia é então utilizada, visto que o medicamento possui aproximadamente quatro vezes e meia o valor do salário mínimo brasileiro conforme medida provisória nº 919, de 30 de dezembro de 2020. Ademais Goldstein et al. (2015) coloca os imunossupressores como medicamentos de alto custo.

Figura 2.3. Custo de estoque dos medicamentos de acordo com seu tipo



Fonte: Autor (2020)

Esse tipo de Medicamento deve dispor de maior controle em toda a cadeia interna de suprimentos, desde sua aquisição até a manipulação nos pacientes. Assim, é possível aplicar estratégias de contenção desses custos no momento de sua aquisição, no gerenciamento de estoque, nas perdas e nas políticas institucionais, McConnell et al. (2017).

Em termo de estoque, os medicamentos são projetados para atender um ciclo de reabastecimento, no qual sua demanda total é fornecida pela quantidade armazenada na instituição, sem que a redução altere a segurança do paciente e a qualidade do atendimento, Syntetos et al. (2015). À vista disso, o sistema evita tanto a escassez quanto o excesso de medicamentos. A escassez porque interrompe tratamentos, que podem resultar em conseqüências desastrosas advinda de sua falta. O excesso porque implica em altos custos operacionais, reduzindo o lucro da organização, Kourentzes

et al. (2019). Assim, é primordial que ao menos medicamentos de alto custo possuam previsões de demanda assertivas, tarefa comumente atribuída como parte das atividades farmacêuticas (e não estatísticas ou matemáticas).

O setor farmacêutico não necessariamente contém os profissionais experientes em operações, compras e serviços clínicos como sugerido por McConnell et al. (2017). Isso, em conjunto com a configuração atual do processo de ressuprimento, a formatação do ERP e o alto nível de serviço exigido, faz com que o erros de previsão sejam altamente elevados nessa instituição.

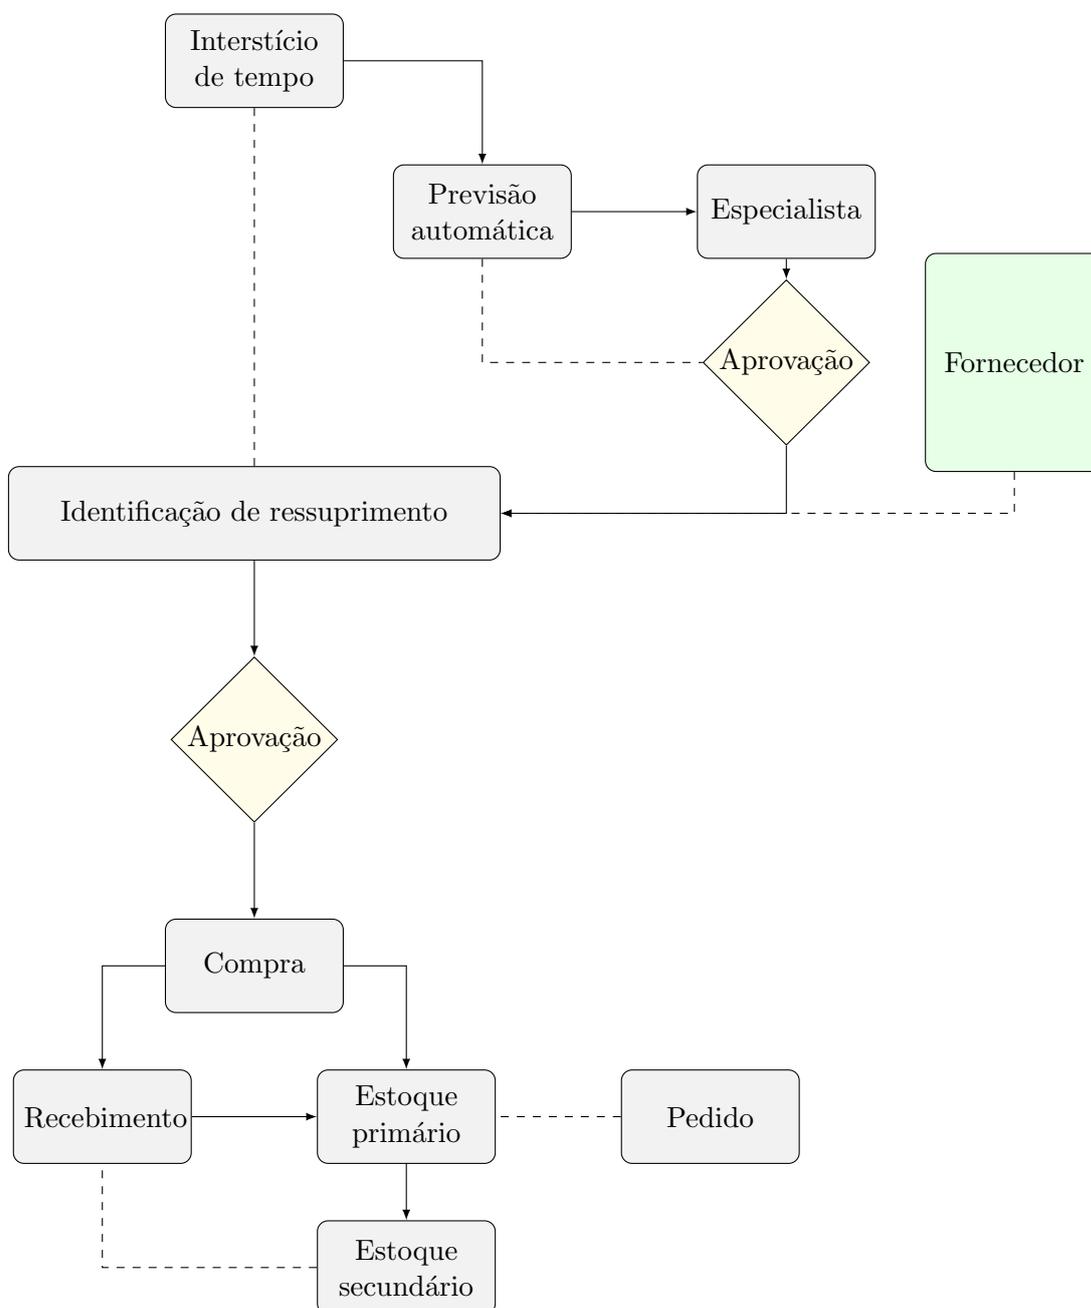
O processo de ressuprimento é demonstrado na Figura 2.4. O interstício de tempo para realização de ressuprimento, devido a acordos institucionais internos, é um mês. Nesse intervalo, o estoque deve abastecer a demanda real. Por essa razão, todo estudo realizado nesta dissertação considera o horizonte de tempo mensal.

Ao fim do interstício é gerada a previsão de demanda automática no sistema ERP, que possui a possibilidade da utilização de técnicas como: revisão periódica, ponto de pedido e média móvel. Técnicas como revisão periódica e ponto de pedido são comumente atreladas ao processo de gestão de estoque e não relacionadas a métodos de previsão, no entanto o ERP da empresa o coloca como tal. No momento da pesquisa, a previsão realizada utilizava o método de médias móveis em um horizonte de tempo de três meses.

O modelo de médias móveis é fundamentado em séries temporais e é projetado com base em suposições de momentos, conhecidos por hipótese de distribuição da demanda, através de média aritmética simples, o que ocasiona erros. Uma reação comum dos responsáveis é incorporar algum viés nas previsões para evitar a falta de estoque, em geral, superestimando a demanda, Syntetos et al. (2015).

Além disso, o especialista analisa e pode alterar a previsão para cima ou para baixo, dependendo do seu conhecimento quanto a necessidade dos pacientes, níveis de estoques e a variação mensal percebida. Esse processo é caracterizado como ordem de ressuprimento e segue para aprovação superior, que pode ser concebida ou não. Se autorizada, a ordem segue para o processo de compras, caso contrário, o processo é finalizado e uma nova previsão deve ser iniciada.

Os procedimentos iniciais de compra são realizados e podem levar até 48 horas para que os fornecedores informem a disponibilidade e o custo de atendimento a demanda. Após analisar os fornecedores respondentes, quanto a confiabilidade da

Figura 2.4. Fluxograma do processo ressuprimento

Autor (2020)

Fonte:

qualidade e entrega, os ganhadores de pedidos são encaminhados para uma nova análise de compra. Ao seu fim, o pedido é encaminhado ao fornecedor.

Internamente o processo de ressuprimento é temporariamente pausado até a data de entrega acordada. Externamente, o fornecedor se encarrega do pedido e o envia ao local solicitado na data estipulada, onde os medicamentos são recebidos, conferidos,

etiquetados e armazenados em um estoque primário.

Diariamente, o setor de atendimento gera pedidos conforme a necessidade de medicamentos. O almoxarifado, responsável pelo armazenamento primário, separa os medicamentos requeridos e o dispensa ao estoque secundário, que é localizado próximo ao local de atendimento. As trocas de informações são representadas pelas linhas pontilhadas e o processo é finalizado caso alguma aprovação não seja concebida.

Todo esse processo demonstra a forte relação entre a previsão de demanda e a gestão de estoque. Visto que, ao realizar uma avaliação confrontando a quantidade média mensal de medicamentos em estoque, dimensionado por intermédio do método de médias móveis, e o total consumido no mês, fica evidente um estoque excessivo de medicamentos de alto custo ocasionado por um processo de previsão inadequado.

Quando detectado problema de excesso ou escassez de medicamentos, entrevistas coletivas com os envolvidos no processo são realizadas para validar as informações e pressupor causas. Fatores como atendimento sob demanda, criticidade do serviço prestado, desconhecimento do sistema de informação, configuração do processo organizacional, longo prazo para ressuprimento e fatores jurídicos, foram citados ao longo do tempo de coleta dos dados.

Quanto aos fatores jurídicos, destacamos:

“Art. 196. A saúde é direito de todos e dever do Estado, garantido mediante políticas sociais e econômicas que visem à redução do risco de doença e de outros agravos e ao acesso universal e igualitário às ações e serviços para sua promoção, proteção e recuperação.”

Constituição Federal de 1988

Lei 9.656 de 3 de junho de 1998, dispõe sobre os planos e seguros privados de assistência à saúde que assegura a cobertura mínima de tratamento contra o câncer.

Mesmo em casos de dúvidas quanto a cobertura contratual, conforme Lei 9.656 de 3 de junho de 1998, a vida humana deve ser priorizada, ocasionando decisões judiciais com cunho de urgência e sob grandes valores monetários.

O conjunto dos fatores influenciadores externos e as crenças e processos internos, geram o superdimensionamento do estoque de medicamentos de alto custo para

garantir o atendimento total da demanda no interstício de tempo entre pedidos, evitando complicações judiciais, pausas nos tratamentos dos pacientes (as quais geram prejuízos irreparáveis) e compras de emergência. Em contra partida, os custos operacionais aumentam e os lucros diminuem. Além disso, a interrupção nas prescrições médicas em relação a determinado medicamento, podem ocasionar estoques inertes que, conseqüentemente, geram perdas por validade.

Assim, é preciso determinar métodos quantitativos com menos controláveis e, conseqüentemente, maiores índices de assertividade para o processo de previsão de demanda, reduzindo ao máximo as desigualdades entre estoque e demanda e garantindo a disponibilidade mensal necessária. Apesar da redução das intervenções, devemos considerar a necessidade de que os métodos aplicados para previsão sejam rápidos, flexíveis, fáceis de usar, capazes de produzir resultados confiáveis e, principalmente, sejam fáceis de serem interpretados por leigos no que tange o conhecimento estatístico avançado, Tratar et al. (2016).

CAPÍTULO 3

MODELOS DE SÉRIES TEMPORAIS

Por definição uma série temporal é um conjunto de observações ordenadas no tempo e que apresentam dependência serial, ou seja, dependência entre instantes de tempo. Com um pouco mais de formalidade, definimos uma série temporal como sendo uma única realização de um processo estocástico ergódico, ou seja, quando apenas uma realização do processo é suficiente para caracterizá-lo, Karlin (2014).

Na literatura encontramos uma ampla gama de modelos distintos usados na descrição do comportamento de uma série particular. A construção destes modelos depende de vários fatores, tais como o comportamento do fenômeno ou o conhecimento a priori que temos de sua natureza e do objetivo da análise. Modelos para previsão é uma área de pesquisa que atraiu muita atenção nas últimas décadas (ver por exemplo, Albrecht et al. (2019); Makridakis et al. (2019); Parmezan et al. (2019); Zhu et al. (2020); Haq et al. (2021)), sendo fundamentais para todas as tarefas de tomada de decisões (Petropoulos et al., 2014). Por exemplo, organizar e sistematizar processos faz com que sejam estabelecidas metas em busca de fatores que possam ser alterados e resultem em um impacto positivo dentro de um objetivo final Makridakis et al. (2008).

Para prever o futuro com acurácia (ou precisão) é necessário o entendimento dos padrões e relacionamentos que existem nos dados históricos, evitando replicar eventos passados descontinuados Hyndman e Athanasopoulos (2018). Segundo Makridakis et al. (2008), para prever com precisão é necessário que os agentes envolvidos tenham conhecimento e habilidade para a identificação e definição de problemas, a aplicação de

métodos de previsão, os procedimentos para selecionar os métodos adequados a cada situação e suporte organizacional para implementação métodos formais.

Com relação aos métodos a serem aplicados, duas situações são possíveis: quando não há dados disponíveis e portanto métodos de previsão qualitativos devem ser aplicados; quando há informação numéricas quantificáveis sobre o passado que possibilita encontrar padrões e, portanto, métodos quantitativos podem ser empregados, Zhu et al. (2020), Makridakis et al. (2008) e Hyndman e Athanasopoulos (2018).

Assim, toda quantidade observada sequencialmente ao longo do tempo, pode ser tratada como uma série temporal, Box et al. (1994); Morettin e Tolo (2006); Jalalpour et al. (2015); Hyndman e Athanasopoulos (2018). Para o embasamento teórico necessário no entendimento, e posterior aplicação, de modelos de séries temporais, neste Capítulo apresentamos os principais conceitos e modelos da área.

3.1 Contextualização

Primeiramente, vamos definir as quantidades em estudo. Imagine uma sequência cronológica, em que a ordem das observações é fundamental e assume o formato X_t ou X_{kt} , que podem ser aferidas no tempo de maneira contínua ou ainda equiespaçada Morettin e Tolo (2006). Estas quantidades podem ser por exemplo aferições diárias, mensais, trimestrais ou anuais (igualmente espaçadas), e representar a grande maioria dos dados de negócios como bolsa de valores e estoque Makridakis et al. (2008).

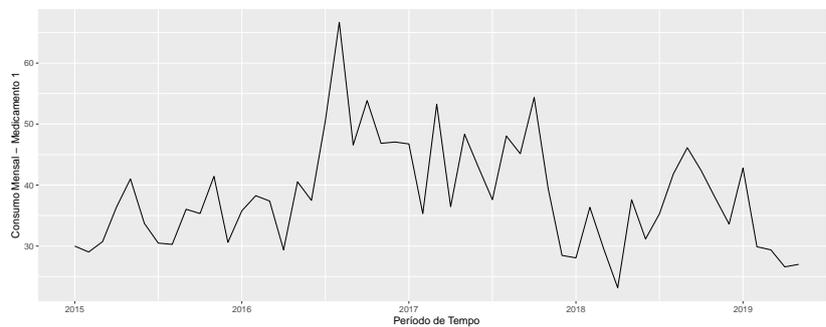
Além do interstício de aferição, as variáveis em estudo podem ser discretas ou contínuas devido sua natureza. No gerenciamento das recursos de cuidados a saúde, objeto de aplicação desta pesquisa, as variáveis em estudo consistem em dados de contagem e, portanto, trata-se de variáveis discretas Jalalpour et al. (2015).

Com os dados aferidos, a coisa mais importante a se fazer para uma análise inicial, é visualizá-los por meio de gráficos. Eles permitem que muitas propriedades dos dados sejam visualizados, incluindo padrões, observações incomuns, alterações ao longo do tempo e relacionamentos entre variáveis Makridakis et al. (2008), Hyndman e Athanasopoulos (2018).

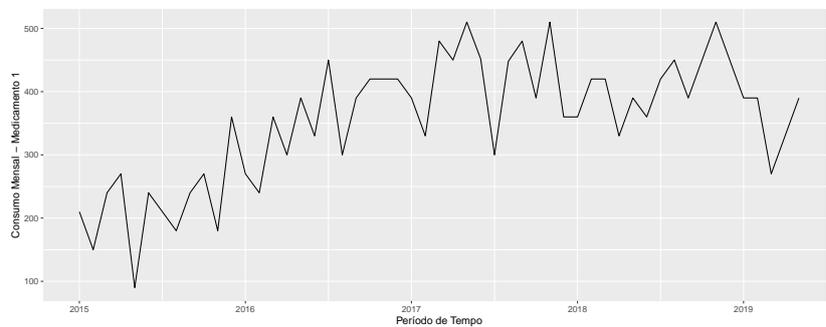
A construção dos gráficos, pode ser aplicada por séries agregadas ou individuais, sendo individualmente mais vantajoso pois, considera propriedades como: tendên-

cia, sazonalidade e volatilidade, de modo singular Wang e Petropoulos (2016). Observações importantes para uma investigação estatística assertiva, uma vez que, precisamos descrever as séries e identificar as classes de modelos estocásticos que são capazes de as representar praticamente Box et al. (1994). Apenas para exemplificar a teoria que será apresentada neste Capítulo, vamos tomar por base as Figuras 3.1-(a) a (c), que representam o consumo ao longo do tempo de três medicamentos distintos (parte dos dados que serão estudados e apresentados no Capítulo 4).

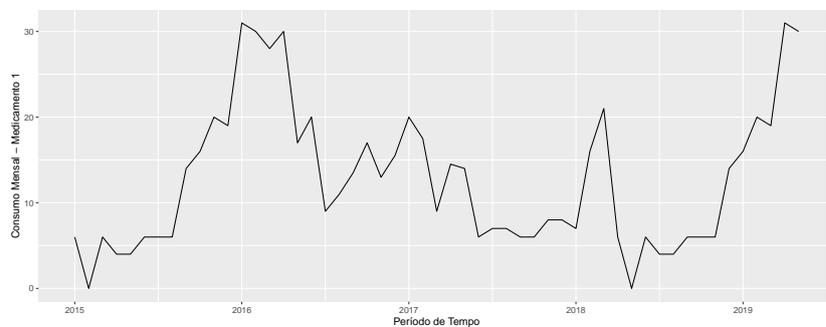
Figura 3.1. Consumo mensal por medicamento



(a) Medicamento 1



(b) Medicamento 2



(c) Medicamento 3

Fonte: Autor (2020)

3.2 Principais modelos univariados

Ao estudar o comportamento de uma série temporal, duas classes de modelos podem ser consideradas: modelos uni e multivariados. Os modelos univariados, foco de estudo deste trabalho, são aqueles em que as séries temporais são explicadas apenas por seus valores no passado. Os multivariados são aqueles explicados por seus valores passados e por outras variáveis.

Dos modelos univariados mais conhecidos e amplamente usados, quatro são apresentados nesta seção: o modelo *naive*, de médias móveis, de amortecimento exponencial e Box & Jenkins.

O mais simples de todos, o método *naive* (ou ingênuo) tem por base que a melhor previsão para o dia seguinte é o valor observado no dia atual, Morettin e Tolo (2006). Logo, não temos a necessidade de *software* para estimação e/ou previsão, basta conhecer o valor observado hoje para prever o amanhã. O modelo de médias móveis é praticamente uma extensão do método *naive*. Ao invés de prever o instante futuro pautado apenas na última observação (instante atual), usa-se as $k > 1$ observações finais. Suponha a série $Y_1, \dots, Y_k, \dots, Y_N$, a previsão será a média simples das k observações mais recentes da série, conforme equação 3.1.

$$Y_{t+1} = \frac{1}{N} \sum_{i=k}^N Y_i. \quad (3.1)$$

Devemos notar que os métodos apresentados até aqui são simplesmente empíricos, baseados no que foi observado, sem levar em consideração tendências, ciclos ou sazonalidades, que serão definidos a seguir.

Definição 1. *A tendência é o componente que representa as variações de uma série temporal, mas de modo geral faz-se ascendente, descendente ou estável.*

Definição 2. *As flutuações periódicas de uma série temporal que retratam o termo da estrutura auto-regressiva da série, são descritas como um ciclo.*

Definição 3. *Uma série temporal que apresenta variações periódicas advindas de manifestações externas pode ser dita sazonal.*

De forma resumida, estes são bons modelos para ajustar séries com tendência constante, o que não observamos nas Figuras 3.1-(a) a (c). Tanto pela simplicidade quanto pelos erros gerados e não controlados, os dois primeiros métodos foram descartados nesta pesquisa.

Nas seções a seguir, apresentamos os modelos que de fato serão aplicados nesta dissertação. Mas antes de caracterizar e apresentar os dois próximos métodos de previsão, um importante conceito no qual ambos são embasados deve ser definido: estacionariedade.

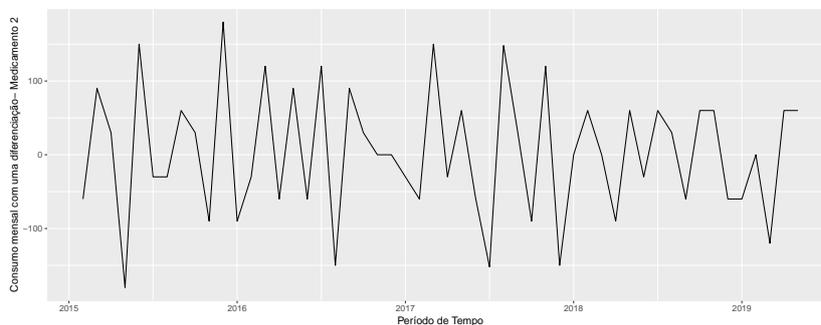
Definição 4. *Uma série temporal é dita estacionária quando ela se desenvolve no tempo aleatoriamente ao redor de uma média constante, refletindo alguma forma de equilíbrio estável.*

Por exemplo, podemos visualizar a Figura 3.1-(b), que apresenta uma série não estacionária de consumo do medicamento 2. Na prática a não estacionariedade é bastante comum, ocorrendo flutuação ao redor diferentes níveis, retas inclinadas ou explosões, ver por exemplo Morettin e Tolo (2006). À vista disso, podem ser usados testes estatísticos para a rejeição ou não da hipótese de estacionariedade das séries, como demonstrado em Wang e Petropoulos (2016) e Yang et al. (2017). Se a série temporal não for estacionária, podemos frequentemente transformá-la com uma das seguintes técnicas: diferenciando os valores, ajustando tendências ou controlando a variabilidade.

A Figura 3.2, apresenta a série para o medicamento 2, ou seja, o segundo medicamento de maior custo, mas agora considerando uma diferenciação. Basicamente, ao diferenciar a série Z_t , criamos a nova série $Y(i) = Z(i) - Z(i-1)$. Consequentemente os dados diferenciados conterão um ponto a menos que os dados originais sendo, em geral, suficiente para que a mesma se torne estacionária (como podemos verificar no exemplo da Figura 3.2, que oscila em torno de 0 e aparentemente de forma constante).

Ou seja, a série assume uma média constante, que define o nível de flutuação, e uma variância constante, que mede sua dispersão nesse nível de tempo. Além disso, considera-se que a covariância entre Y_t e Y_{t+k} , separados por k intervalos de tempo, deve ser a mesma para para todo t . Assim a distribuição de probabilidade $F(Y)$ é a mesma para todos os tempos t , ver por exemplo Box et al. (1994), Morettin e Tolo (2006) e Fuller (2009). Uma outra forma de verificar a estacionariedade de uma série, é através de sua função de autocorrelação (FAC). Por capturar a influência do tempo passado no tempo presente é natural que no gráfico da FAC para um processo estacionário o

Figura 3.2. Consumo mensal do medicamento 2 considerando uma diferenciação.



Fonte: Autor (2020)

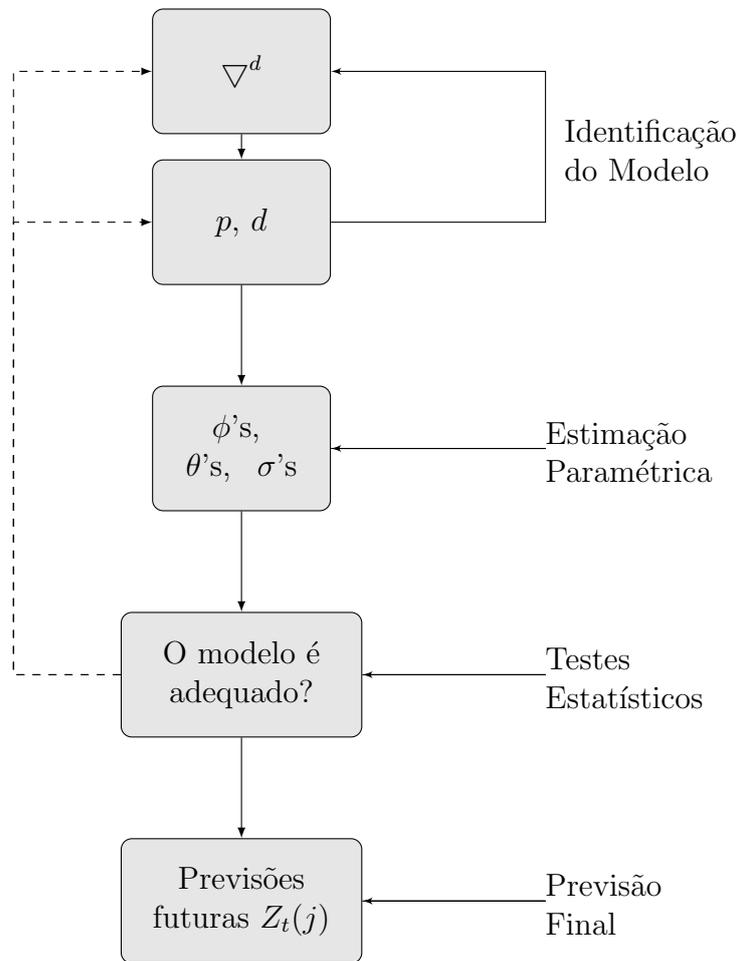
decaimento seja rápido, tendendo a zero, ou que desde o início os valores observados sejam próximos de zero. Estas funções serão melhor discutidas na Seção 3.2.1.

3.2.1 Modelos de Box & Jenkins

A mais conhecida e amplamente aplicada na análise de modelos paramétricos de séries temporais, nesta são apresentadas as abordagens de Box & Jenkins (1970). Artigos como Wang et al. (2015) e Ruiz et al. (2016) utilizam esses modelos para previsão de problemas encontrados em âmbito da saúde, como o apresentado nesta dissertação. Tal metodologia consiste em ajustar modelos auto-regressivos integrados de médias móveis, ARIMA (p, d, q), a um conjunto de dados usando como estratégia para construção um ciclo iterativo no qual a escolha da estrutura do modelo baseia-se nos próprios dados, como apresenta o fluxograma da Figura 3.3, Box et al. (1994). Nela ∇^d corresponde ao grau de diferenciação determinado para estacionarização da série.

O modelo auto-regressivo integrado de médias móveis (ARIMA) é comumente utilizado para previsões Box et al. (2015), sendo originado dos modelos auto-regressivos (AR), médias móveis (MA), e a combinação de ambos (ARMA). Assim, ele é uma importante classe de modelos ARMA com propriedade que permitem sua estacionariedade a partir de d diferenciações na série temporal, como apresentado anteriormente para o Medicamento 2, Box et al. (1994).

O modelo AR é usado para descrever equações com valores atrasados no tempo em relação a variável de previsão e possui as variáveis do lado direito como valores anteriores da variável de previsão Y_t (Makridakis et al., 2008). O modelo é dado pela equação 3.2.

Figura 3.3. Ciclo iterativo de escolha da estrutura do modelo.

Fonte: Autor (2020)

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t. \quad (3.2)$$

O que diferencia a equação 3.2 dos modelos de regressão comuns é que a suposição de independência dos termos de erro pode ser violada, uma vez que, as variáveis explicativas da equação usualmente têm uma relação de dependência interna e determinam o número de valores passados de Y_t a serem considerados na equação.

Por ser possível regredir em relação aos valores passados da série, é possível regredir em termos de erros passados. O modelo de série temporal que usa erros como variáveis explicativas é denominado médias móveis (MA) Box et al. (1994), e é expresso pela equação 3.3.

$$Y_t = a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q}, \quad (3.3)$$

Representa um modelo de médias móveis de ordem q , MA(q), com variação do termo de erro a_t que alteram apenas a escala da série, não os padrões, Hyndman e Athanasopoulos (2018). Segundo Makridakis et al. (2008), nela é estabelecida uma relação de dependência entre os termos sucessivos de erro.

Os modelos AR(p) podem ser acoplados aos modelos MA(q) para formar uma classe geral e útil de modelos de séries temporais denominados modelos de média móvel auto-regressivos (ARMA). Um modelo ARMA (p, q) de ordem p e q é definido por Yang et al. (2017) por intermédio da equação 3.4.

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + a_t - \theta_1 a_{t-1} - \theta_2 a_{t-2} - \dots - \theta_q a_{t-q} \quad (3.4)$$

Em que Y_t é a série ARMA, o termo estocástico a_t é a série de ruído branco independente, ϕ_p é o coeficiente de autocorrelação e θ_q é o coeficiente da média móvel. Se $p = 0$, a equação se torna um modelo MA de ordem q , e se $q = 0$, ele se torna um modelo AR de ordem p , Yang et al. (2017). No entanto, eles só podem ser usados quando o comportamento da série é estacionário. Por fim, a classe de modelos ARIMA (p, d, q) pode ser estendida para séries não estacionárias, permitindo a d -ésima diferenciação na série de dados. O modelo completo pode ser escrito conforme a equação 3.5.

$$Y'_t = c + \phi_1 Y'_{t-1} + \dots + \phi_p Y'_{t-p} + \theta_1 a_{t-1} + \dots + \theta_q a_{t-q} + a_t \quad (3.5)$$

Y'_t é a série que pode ser diferenciada em um número finito de vezes, os preditores no lado direito incluem valores atrasados de y_t e erros, Hyndman e Athanasopoulos (2018). Na literatura este modelo é chamado de ARIMA (p, d, q), em que p corresponde a AR, d a I como o grau de diferenciação necessária para a estacionariedade, e q a MA.

Mais especificamente, dentre a variedade de modelos ARIMA, os termos e suas identificações são dispostos da seguinte maneira:

- I:** d = grau de diferenciação envolvida. Utiliza-se para a identificação o gráfico da série diferenciada $\nabla^d Z^t$ sendo $d = 0, 1, \dots$ o valor de d que “estacionarizou” ou “horizontalizou” a série.

AR: p = ordem da parte autorregressiva e;

MA: q = ordem da parte da média móvel. A identificação deve ser feita por meio da FAC e FACP com os correspondentes padrões teóricos.

Antes de discutirmos estes padrões teóricos da FAC e FACP, vamos defini-las.

Definição 5. A função de autocorrelação, FAC, é o gráfico da autocorrelação contra a defasagem. Considere uma série temporal de retornos de uma ação $\{r_t\}_{t=1}^T$. O coeficiente de correlação entre r_t e r_{t-k} é chamado de autocorrelação de k -ésima ordem (ou lag) e é denotada por:

$$\rho = \frac{\text{Cov}(r_t, r_{t-k})}{\text{Var}(r_t, r_{t-k})} = \frac{\text{Cov}(r_t, r_{t-k})}{\text{Var}(r_t)} = \frac{\gamma_k}{\gamma_0}$$

onde $\text{Var}(r_{tk}) = \text{Var}(r_t)$ porque r_t é fracamente estacionário. Além disso, temos:

- $\rho_0 = 1$;
- $\rho_t = \rho_{-t}$;
- $-1 \leq \rho \leq 1$.

Um conjunto de autocorrelações, $\{\rho_k\}$, é chamado de função de autocorrelação de r_t . Para uma dada amostra de retornos de uma ação, $\{r_t\}_{t=1}^T$, suponha que \bar{r} é a média amostral. Então, a autocorrelação amostral de k -ésima ordem de r_t é definida como:

$$\hat{\rho} = \frac{\sum_{t=k+1}^T (r_t - \bar{r})(r_{t-k} - \bar{r})}{\sum_{t=k+1}^T (r_t - \bar{r})^2},$$

para $0 \leq k \leq T - 1$.

Definição 6. A função de autocorrelação parcial, FACP, corresponde à correlação de Y_t e Y_{t-k} removendo o efeito das observações $Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1}$ e é denotada por ϕ_{kk} , ou seja

$$\phi_{kk} = \text{Corr}(Y_t, Y_{t-k} / Y_{t-1}, Y_{t-2}, \dots, Y_{t-k+1})$$

Um método geral para encontrar a FACP para um processo estacionário com FAC ρ_k é utilizando as equações de **Yule-Walker**, isto é, para um certo k temos

$$\rho_j = \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \cdots + \phi_{kk}\rho_{j-k}, \quad j = 1, 2, \dots, k$$

Desenvolvendo a equação temos

$$\begin{aligned} \rho_1 &= \phi_{k1} + \phi_{k2}\rho_1 + \cdots + \phi_{kk}\rho_{j-1} \\ \rho_2 &= \phi_{k1}\rho_1 + \phi_{k2} + \cdots + \phi_{kk}\rho_{j-2} \\ \vdots &= \vdots \\ \rho_j &= \phi_{k1}\rho_{j-1} + \phi_{k2}\rho_{j-2} + \cdots + \phi_{kk} \end{aligned}$$

Resolvendo as equações acima sucessivamente para $k = 1, 2, \dots$, obtemos

$$\phi_{kk} = \frac{|P_k^*|}{|P_k|}$$

onde P_k é a matriz de autocorrelação, e P_k^* é a matriz P_k com a última coluna substituída pelo vetor de autocorrelação.

Alguns padrões podem ajudar na especificação dos termos AR e MA de um modelo ARIMA:

1. Um grande pico no *lag* 1 que diminui depois de alguns *lags*: significa, em palavras, um termo auto-regressivo nos dados. Desta forma, usamos a função de autocorrelação para determinar a ordem do termo AR.
2. Um grande pico no *lag* 1 seguido por uma onda decrescente que alterna entre correlações positivas e negativas: significa a presença de um termo auto-regressivo de ordem superior nos dados. Devemos usar a função de autocorrelação parcial para determinar a ordem do termo auto-regressivo.
3. Correlações significativas no primeiro ou segundo *lag*, seguidas por correlações não significativas: indica um termo de média móvel nos dados e o número de

correlações significativas aponta a ordem do termo.

Já as FACP's devem ser analisadas da seguinte forma:

1. Em um modelo AR(p) a FACP é da forma: $\left\{ \begin{array}{l} \phi_{kk} \neq 0, \quad \text{se } k \leq p \\ \phi_{kk} = 0, \quad \text{se } k > p \end{array} \right\}$;
2. O modelo MA(q) a FACP se comporta de maneira similar à FACP de um processo AR(p), isto é, composta por exponenciais e/ou senoides amortecidas.
3. O modelo ARMA(p,q) tem FACP que se comporta como a FACP de um processo MA puro.

Dados os fatores supracitados, segue que a FACP é útil para identificar modelos AR puros, não sendo tão útil para identificar modelos MA e ARMA.

Ademais a FAC é o princípio de outro importante conceito para os modelos de séries temporais: ruído branco. Séries temporais simétricas, com dados não correlacionados entre instantes diferentes, e valor esperado e variância constantes, são denominada ruído branco.

Definição 7. *Ruído Branco é uma série de tempos estacionárias com FAC nulas, ou seja, $\rho_j = 0 \forall j = 1, 2, \dots, N$.*

Após escolha do modelo, passamos às outras etapas. Para estimação usaremos o método de máxima verossimilhança, por se tratar de um método simples, rápido computacionalmente e implementado na maioria dos *softwares* estatísticos, incluindo o R. Esse é um software livre, ou seja uma ferramentas gratuitas e de código aberto, que garante o acesso a todos. Sua popularização gera perspectivas de desenvolvimento em ambientes empresariais e acadêmicos.

Com relação à análise de adequabilidade do modelo, testes estatísticos serão realizados. O primeiro teste, o de sobrefixação, nos auxilia na verificação do grau do modelo, ajustando um modelo com um número maior de parâmetros para verificar se estes parâmetros extras são significativos. Outra forma de verificar a adequabilidade é por meio da análise de resíduos, que não devem assumir nenhuma estrutura de dependência, devendo apresentar média em torno de zero e variância constante. Além disso a FAC não deve ser significativa em nenhum *lag* e o teste a ser aplicado aqui é o de Ljung e Box, Hipel et al. (1977); Ljung (1986).

A seleção do modelo final será pautada em critérios já conhecidos e amplamente utilizados: AIC (*Akaike Information Criterion*), BIC (*Bayesian Information Criterion*) e Shwartz (*SBC Criterion*). Finalmente, a previsão será discutida de acordo com o modelo selecionado e apresentada no Capítulo 4 juntamente com os resultados.

3.2.2 Modelo de suavização ou amortecimento exponencial

Introduzidos na literatura por Brown (1959) e amplamente aplicados (ver por exemplo Bergmeir et al., 2016; de Oliveira e Oliveira, 2018), os modelos de suavização são uma grande classe de métodos de previsão que se baseiam na ideia de que observações passadas contêm informações sobre o padrão da série temporal. O propósito dos métodos é distinguir um padrão de comportamento de qualquer outro ruído que possa estar contido nas observações da série e então usar esse padrão para prever valores futuros.

Os modelos de suavização são poderosas ferramentas para diminuir os ruídos nas séries temporais, prever a demanda futura e reduzir os custos de estoque Tratar et al. (2016). Seu princípio básico para distrição dos comportamento é que os valores mais recentes são mais consideráveis para a previsão, ou seja, eles possuem pesos que decaem de maneira exponencial do ponto de dados mais recente ao mais distante, Syntetos et al. (2015) e Makridakis et al. (2008).

Esse comportamento é característico de essencialmente quatro métodos, a suavização exponencial simples (SES), o método de Brown (BES), a suavização exponencial com tendência (SEH) e a suavização exponencial com tendência e sazonalidade (HW), Makridakis et al. (2008).

O SES é o método mais simples de suavização exponencial e é adequado para a previsão de dados sem tendência clara ou padrão sazonal, Hyndman e Athanasopoulos (2018). Pode ser escrito conforme a equação 3.6, Syntetos et al. (2015).

$$S_t = \alpha y_t + (1 - \alpha)S_{t-1}, \quad (3.6)$$

Sendo α é o parâmetro de suavização, y_t o valor observado da demanda, e S_t é a média suavizada, bem como a previsão para o próximo período, Syntetos et al. (2015). Quando α tem um valor próximo de 1, a nova previsão incluirá um ajuste

substancial para o erro na previsão anterior. Por outro lado, quando α é próximo de 0, a nova previsão incluirá poucos ajustes.

O BES é usualmente utilizado em previsões de curto prazo sendo apropriado quando o valor previsto advém de séries de dados com tendência. A previsão para o método BES é obtido de modo similar ao SES, usando uma única constante de parâmetro α com valor entre 0 e 1. Sua equação é demonstrada em 3.7, Basetti et al. (2016), Chen et al. (2008) e Syntetos et al. (2015):

$$S'_t = \alpha S_t + (1 - \alpha)S'_{t-1}, \quad (3.7)$$

em que S_t é a suavização exponencial simples e S'_t é a suavização exponencial dupla. O método de Brown também é chamado de método de suavização exponencial dupla.

O SEH é um tipo de técnica de suavização exponencial frequentemente usada para lidar com uma tendência linear. O nível da série em conjunto com a tendência, são suavizados por intermédio de diferentes constantes, α e β , Makridakis et al. (2008). As equações 3.8, 3.9 e 3.10 representam o método de Holt.

$$l_t = \alpha y_t + (1 - \alpha)(l_{t-1} + b_{t-1}), \quad (3.8)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1}, \quad (3.9)$$

$$\hat{y}_{t+h|t} = l_t + b_t m \quad (3.10)$$

Denote l_t uma estimativa do nível da série no tempo t e b_t uma estimativa da tendência da série no tempo t . A equação 3.8 ajusta l_t para a tendência do período anterior, b_{t-1} , adicionando-a ao último valor suavizado, l_{t-1} . Isso leva l_t ao nível aproximado do valor atual dos dados. A equação 3.9 atualiza a tendência, que é expressa como a diferença entre os dois últimos valores suavizados. Como pode haver aleatoriedade nos dados, a tendência do último período, $(l_t - l_{t-1})$, é suavizada com β e adicionada à estimativa anterior da tendência multiplicada por $(1 - \beta)$. Finalmente, a equação 3.10 é usada para fazer estimativas do valor dos períodos a serem previstos, m .

A diferença entre a abordagem de Holt e Brown é que a última usa apenas uma constante de suavização e que os valores de tendência estimados são muito sensíveis a influências aleatórias. Diferentemente da técnica de Brown, mais flexibilidade é dada

pela técnica de Holt na seleção das taxas constantes de suavização, Chen et al. (2008).

O método de Holt utiliza dois parâmetros diferentes e permite a previsão de séries com tendência. O método de Holt-Winters (HW) envolve três parâmetros de suavização para atenuar os dados de nível, tendência e sazonalidade, Makridakis et al. (2008).

As séries temporais observadas são representadas por y_1, y_2, \dots, y_t . Denote s_t uma estimativa do componente sazonal no tempo t . Um ciclo sazonal completo consiste em m períodos. Usamos a notação $\hat{y}_{t+h|t}$ para denotar uma previsão pontual de y_{t+h} usando as informações disponíveis no tempo t Tratar et al. (2016).

Existem duas variantes para o método: a aditiva e a multiplicativa, dependendo da variação sazonal ser independente do nível da média local ou proporcional a ela. No método aditivo, o componente sazonal é expresso em termos absolutos na escala das séries observadas. A equação de nível é então, ajustada sazonalmente subtraindo o componente sazonal, Hyndman e Athanasopoulos (2018).

Assim o método aditivo é um problema típico na modelagem da demanda por itens individuais Tratar et al. (2016) e suas equações são 3.11, 3.12, 3.13 e 3.14, Makridakis et al. (2008).

$$l_t = \alpha(y_t - s_{t-m}) + (1 - \alpha)(l_{t-1} + b_{t-1}) \quad (3.11)$$

$$b_t = \beta(l_t - l_{t-1}) + (1 - \beta)b_{t-1} \quad (3.12)$$

$$s_t = \gamma(y_t - l_t) + (1 - \gamma)s_{t-s} \quad (3.13)$$

$$\hat{y}_{t+h|t} = l_t + b_t m + s_{t-s+m} \quad (3.14)$$

O método multiplicativo possui igualmente quatro equações, sendo a segunda delas (3.12) permanece a mesma e as outras, possuem alterações relativas aos componentes sazonais. Aqui, eles aparecem em forma de produtos e proporções, em vez de serem adicionados e subtraídos, Tratar et al. (2016). A série é ajustada sazonalmente, sendo dividida pelo componente sazonal. Dentro de cada ano, o componente sazonal totalizará aproximadamente m , Hyndman e Athanasopoulos (2018).

CAPÍTULO 4

RESULTADOS

Nesta Seção apresentamos os resultados da aplicação tanto da parte organizacional do sistema de estoque de medicamentos de alto custo, quanto das técnicas e teorias estatísticas para análise dos dados, modelagem e previsão de demanda.

Antes de iniciarmos qualquer análise mais aprofundada, vamos entender os dados. Inicialmente a empresa forneceu para esta pesquisa os dados referentes aos estoques, compras e consumo (mediante prescrição médica) de 163 medicamentos usados no setor de oncologia à partir de janeiro de 2015. Primeiro é importante notar que não foi possível obter a série completa de dados para todos os medicamentos.

Diante dos dados e da organização para compra dos medicamentos, retiramos do nosso conjunto de dados os medicamentos de acordo com os seguintes critérios:

1. independentemente do custo, o fármaco é usado apenas em casos muito específicos, ou casos raros: estes medicamentos são comprados de acordo com a autorização do especialista e não necessita de modelo de previsão;
2. fármacos mais recentes e que passaram a ser utilizados após janeiro de 2019;
3. medicamentos com representatividade inferior a 5% no valor total do estoque; e
4. medicamentos com alto custo e baixa prescrição.

Para facilitar o entendimento a Figura 4.1 foi construída, agrupando os me-

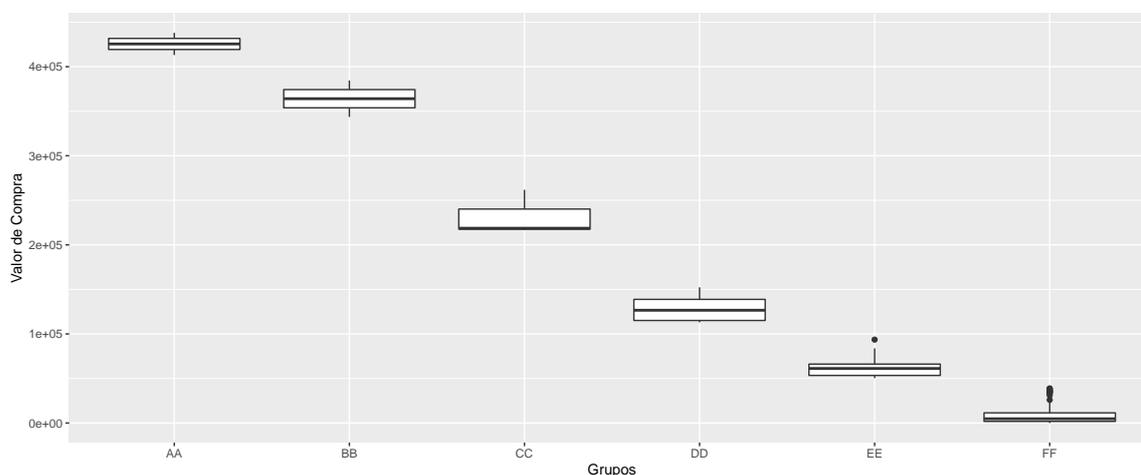
Tabela 4.1. Grupos de Medicamentos

Grupos	AA	BB	CC	DD	EE	FF
Número de Medicamentos	2	2	3	8	17	131

Fonte: Autor (2020)

dicamentos conforme sua representatividade econômica no estoque. Consideramos a formação de seis grupos (Tabela 4.1) de acordo com a demanda e custo.

Apesar de os dois primeiros grupos serem representados apenas por dois medicamentos cada, notem os respectivos impactos financeiro. Estes quatro medicamentos impactam juntos mais que o acumulado dos outros 159 medicamentos.

Figura 4.1. Valor dos Medicamentos Oncológicos em Estoque

Fonte: Autor (2020)

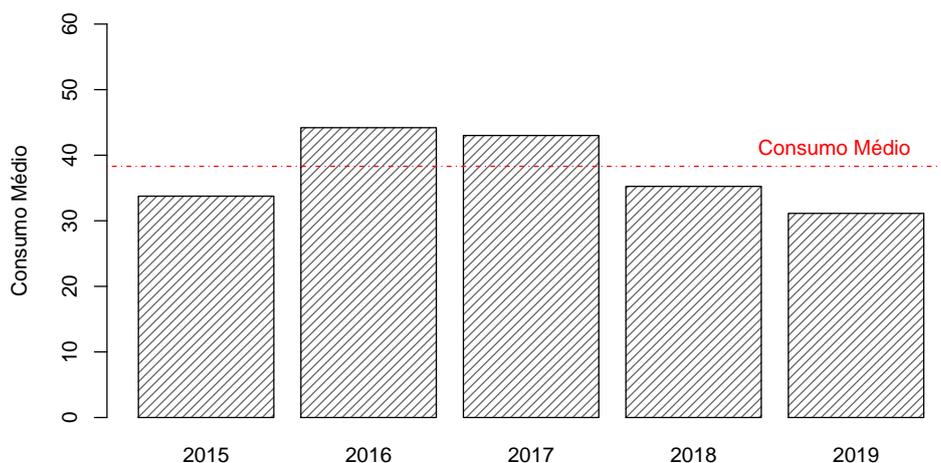
Neste ponto do relatório, já mostramos que os medicamentos oncológicos são os que mais impactam, ao menos no quesito financeiro, tanto para compra quanto para manutenção no estoque. Dentre estes, os medicamentos do grupo AA são os que mais impactam no estoque da organização e seus consumos ao longo do tempo pode ser visualizado nas Figuras 3.1-(a) e (b).

Para fim desse estudo, focaremos na modelagem e previsão do Medicamento 1, ou seja, o de maior impacto financeiro. Sua série de dados tem início em janeiro de 2015 e fim em maio de 2019, totalizando 53 observações obtidas mensalmente. O sistema disponibiliza dados diários que tiveram seu horizonte de tempo facilmente convertidos e combinados conforme tabela 2.1.

O consumo médio mensal de medicamentos ao longo dos 4 anos analisados foi de aproximadamente 38,30 doses, que pode ser comparado com os consumos médios

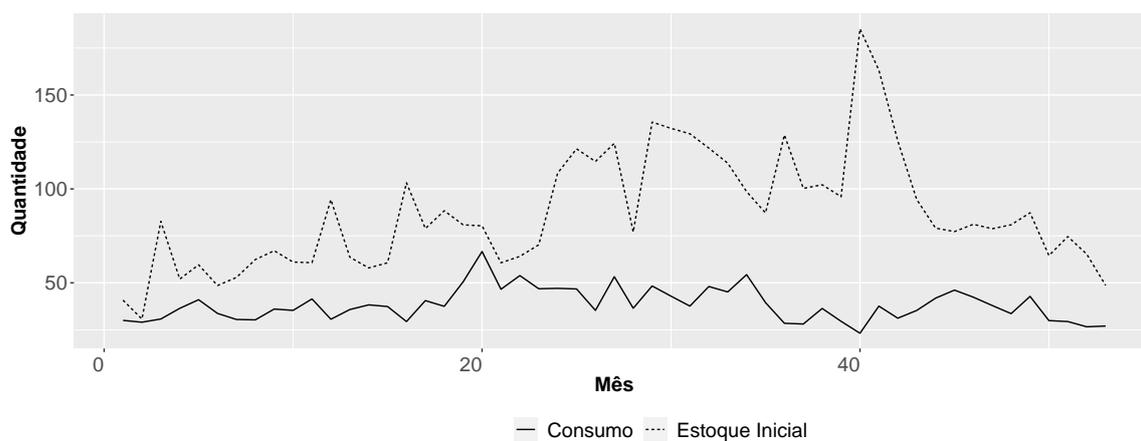
mensais do medicamento ao longo dos anos (Figura 4.2), o que gera um coeficiente de variação de 15,2% e desvio padrão de 5,8 doses. Além disso, o valor médio de doses de medicamentos ao início de cada mês foi de aproximadamente 87,15 doses, evidenciando a compra em excesso (Figura 4.3).

Figura 4.2. Consumo médio mensal ao longo dos anos e média mensal global do consumo do Medicamento



Fonte: Autor (2020)

Figura 4.3. Estoque e consumo mensal de Medicamentos



Fonte: Autor (2020)

Para o processo de previsão, a série de observações será dividida em duas partes:

- a primeira parte será nomeada série de treino. Esta série será usada para ajuste e estimação dos parâmetros do modelo. Neste caso, consideramos os 41 primeiros meses, ou seja, de janeiro de 2015 à maio de 2018, compreendendo aproximadamente 75% do tempo de consumo estudado.
- a segunda parte será nomeada série de teste. Esta série será usada para verificação da previsão do modelo. Após ajustados os diferentes modelos iremos comparar o que foi estimado com o que seria observado na prática, apenas para termos uma referência. Na prática nunca teremos esta base de teste e teremos que aguardar o fim de cada mês para sabermos o quão acertiva foi a nossa previsão. Os meses de teste compreendem aproximadamente 25% do tempo final de consumo estudado.

4.1 Modelagem e avaliação do ajuste dos modelos

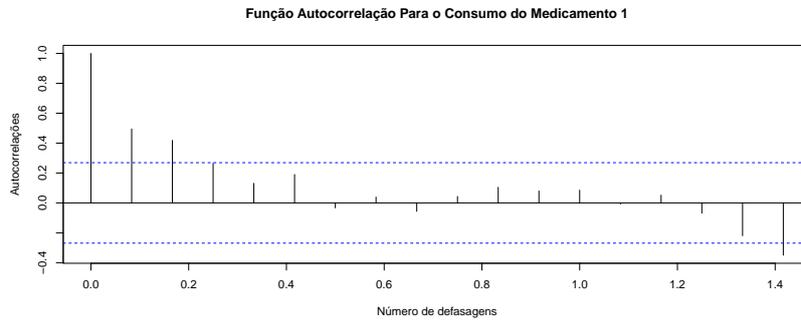
Com o objetivo de prever o comportamento do consumo do medicamento, apresentamos aqui duas diferentes modelagens: uma pautada na metodologia de Box & Jenkins e outra em modelos de suavização exponenciais de Holt-Winters (aditivo e multiplicativo).

Como descrito no início da Seção 3.2.1, os métodos determinados para modelagem dos dados são embasados no conceito de estacionariedade, como o são a maioria dos métodos propostos na literatura de séries temporais. Para checar este pressuposto, aplicamos o teste estatísticos de Dickey-Fuller aumentado e as seguintes hipóteses foram testadas:

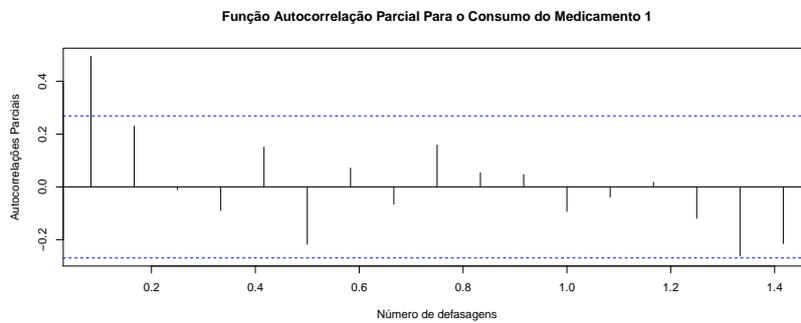
$$\begin{cases} H_0 : \text{o processo é estacionário} \\ H_1 : \text{o processo não é estacionário} \end{cases}$$

Estimando $p\text{-valor} = 0,5181$, ou seja, não existem evidências estatística para rejeitar a estacionariedade da série. Com a hipótese de estacionariedade não rejeitada, é desnecessário o processo de diferenciação para transformação do comportamento dos dados. A FAC e FACP são geradas (Figuras 4.4-(a) e (b)) para complementar a análise e permitir a visualização de padrões de correlação que podem ajudar na especificação dos termos AR e MA de um modelo ARIMA.

A Figura 4.4(a) demonstra um grande pico no *lag* 1 que diminui depois de

Figura 4.4. Função autocorrelação

(a) Função autocorrelação (FAC)



(b) Função autocorrelação parcial FACP

Fonte: Autor (2020)

alguns *lags* o que sugere um termo auto-regressivo nos dados. O pico é seguido por uma onda decrescente que alterna entre correlações positivas e negativas o que indica possivelmente a presença do termo auto-regressivo de ordem superior. A FACP determina a ordem do termo auto-regressivo por intermédio da quantidade de *lags* significativos, apontando para um possível modelo AR(1) ou AR(2).

4.2 Ajuste do modelo de Box & Jenkins

Após análise visual das FAC e FACP, os dois modelos auto-regressivos foram testados, tanto o de ordem 1 como o de ordem 2. Após análises mais aprofundadas, como mostraremos no decorrer desta seção, o modelo de Box & Jenkins com maior parcimônia à série de consumo foi o AR(2). Este modelo também foi o selecionado pelas funções automáticas de seleção do *software* R.

Desta forma, o modelo selecionado para o ajuste é o modelo ARIMA (2,0,0)

ou AR(2), dado por

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + a_t, \quad (4.1)$$

e as estimativas do modelo são apresentadas na Tabela 4.2 bem como algumas estimativas que serão usadas mais adiante para seleção de modelo, Tabela 4.3.

Tabela 4.2. Estimativas dos parâmetros do modelo de AR(2)

Parâmetro	Estimativa	Erro Padrão
ϕ_1	0.5205	0.1409
ϕ_2	0.4610	0.1415

Fonte: Autor (2020)

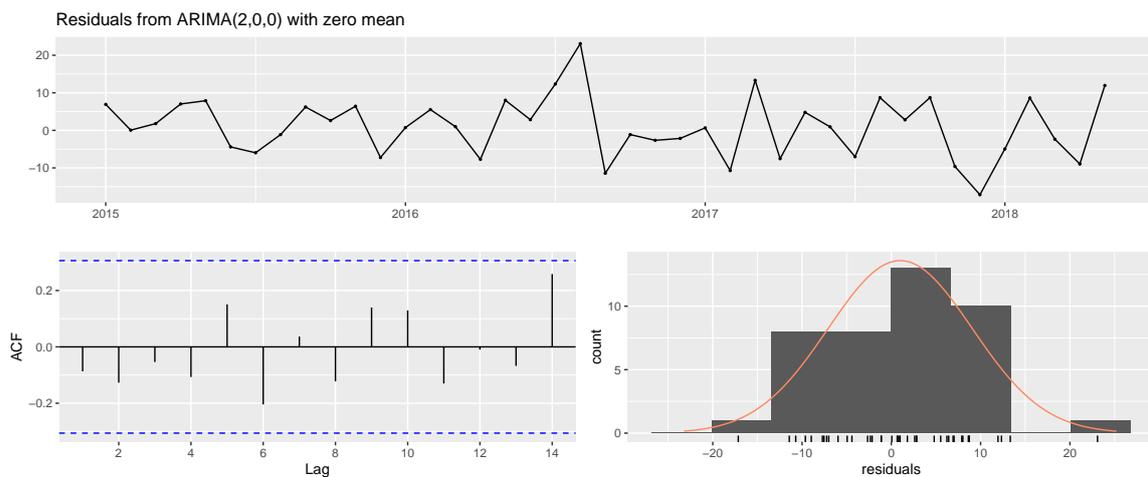
Tabela 4.3. Critérios de seleção de modelo σ^2 , Akaike (AIC) e log verossimilhança.

Critério	Estimativa
σ^2	65.57
AIC	296.4
$-2 \log$ Verossimilhança	-145.2

Fonte: Autor (2020)

A fim de verificar a adequabilidade do modelo estimado, calculamos a diferença entre o valor estimado \hat{y}_t e o valor real y_t , chamados resíduos do modelo. Na Figura 4.5 apresentamos a série dos resíduos do modelo estimado, sua função autocorrelação e o histograma com a distribuição desses resíduos.

Figura 4.5. Valores residuais do modelo AR(2)



Fonte: Autor (2020)

Primeiro vamos analisar a autocorrelação, importante ferramenta para investigar as propriedades de uma série temporal, principalmente no caso de uma série de

“ruído branco”. Para dados não correlacionados, é esperado que cada autocorrelação seja próxima de zero, como podemos observar, Makridakis et al. (2008). Além disso esperamos que estes resíduos sejam normalmente distribuídos com média zero e variância constante. Nas Figuras podemos verificar que os erros estão todos em torno de zero e sua distribuição é aproximadamente simétrica, indicando normalidade.

Apesar de todos os indicativos visuais, testes estatísticos foram feitos para sustentação das suposições de adequabilidade (resíduos estacionários, com distribuição gaussiana e autocorrelações nulas) do modelo AR(2). Para tal, usamos o teste de Ljung-Box, Box-Pierce, Shapiro-Wilk e Jarque Bera, para avaliar as hipóteses de autocorrelação e normalidade.

O primeiro teste, Ljung-Box, analisa se a presença de autocorrelação é estatisticamente válida em uma série temporal por meio de um teste de variabilidade geral com base em vários atrasos, Meyer e Shera (2017). Ele também é conhecido como Ljung-Box Q e está intimamente relacionado ao teste Box-Pierce. A estatística do teste Box-Pierce é uma versão simplificada, amplamente aplicada, da estatística do teste Ljung-Box, Meyer e Shera (2017).

Para a hipótese de distribuição normal aplicamos o teste de Shapiro-Wilk, Razali et al. (2011). Análogo ao teste de Shapiro-Wilk, o teste de Jarque-Bera será usado como uma complementação pois detecta desvios na normalidade da série, devido à assimetria ou curtose. Na Tabela 4.4 apresentamos os p-valores mostrando que, ao nível de 5% não existem evidências nem para rejeitar a normalidade nem a independência dos resíduos (todos os p-valores $> 0,05$). Podemos concluir então que o modelo ajustado apresenta ruídos brancos, ou seja, ruídos estacionários, com autocorrelações aproximadamente nulas e distribuição gaussiana.

Tabela 4.4. Testes de Resíduos - ruídos brancos

Testes	p-valor
Ljung-Box	0.5639
Box-Pierce	0.5779
Shapiro-Wilk	0.8934
Jarque-Bera	0.9033

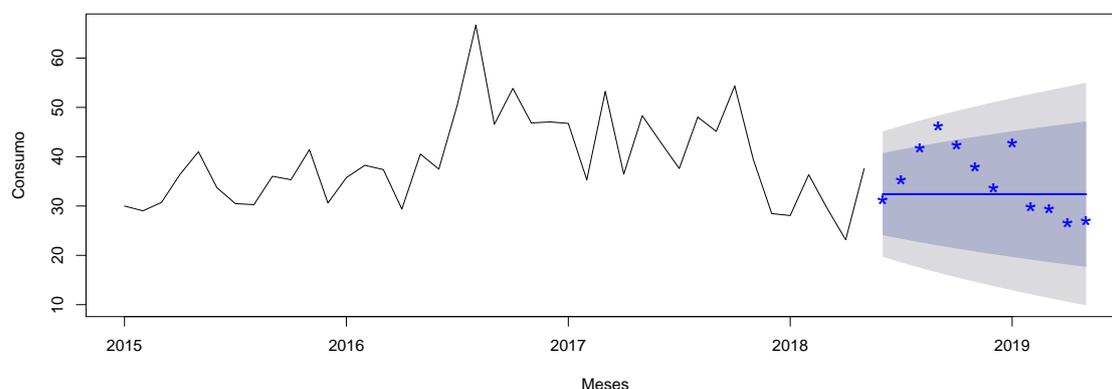
Fonte: Autor (2020)

Uma vez que o modelo está bem ajustado, na Figura 4.6 apresentamos a previsão estimada de consumo (e portanto demanda para compra) e o que foi de fato observado pela empresa (base de teste) para o próximo ano. Para checar a acurácia da previsão estimamos erro médio (ME) e raiz do erro quadrático médio (RMSE),

respectivamente iguais a 0,9973 e 8.0353.

Nesse cenário, faltariam 0,9973 doses de medicamentos por mês a um desvio médio (entre as observações e as previsões) de 8.0353 doses, o que demonstra uma falta mínima porém significativamente não uniforme. Assim, em alguns meses a escassez de medicamentos deve ser expressiva enquanto em outros é constatado um excesso. Ademais, é comum que RMSE dos dados de treino sejam inferiores ao RMSE dos dados de teste, o que iremos discutir futuramente.

Figura 4.6. Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado AR(2) comparada com a demanda observada.



Fonte: Autor (2020)

4.3 Ajuste dos modelos de Holt-Winters

Dentre todos os possíveis modelos de amortecimento exponencial, o que melhor se ajustou à série de consumo foi o de Holt-Winter. Para este modelo, consideramos as versões aditivas e multiplicativas.

4.3.1 Ajuste do modelo de Holt-Winters aditivo

Com expressões mais sofisticadas que os modelos de Box & Jenkins, o primeiro modelo de suavização exponencial estimado foi o modelo aditivo de Holt-Winters (HWA), representado nas equações 4.2, 4.3 e 4.4.

$$l_t = 0.3697(y_t - s_{t-m}) + (1 - 0.3697)(l_{t-1} + b_{t-1}) \quad (4.2)$$

$$b_t = 1e^{-4}(l_t - l_{t-1}) + (1 - 1e^{-4})b_{t-1} \quad (4.3)$$

$$s_t = 1e^{-4}(y_t - l_t) + (1 - 1e^{-4})s_{t-m} \quad (4.4)$$

Nestes modelos estimamos as constantes de suavização α e β , e desta forma determinamos os valores iniciais para l , b e s . Os dois primeiros exigem a estimação de apenas um valor, sendo $l_0 = 30.057$ e $b_0 = 0.0474$, respectivamente. A variável sazonal s , deve ser estimada para cada período a ser previsto e pode ser vista na Tabela 4.5.

Tabela 4.5. Parâmetros sazonais iniciais (s)

Mês	Parâmetro
Jun	-5.5466
Jul	2.6147
Ago	7.6830
Set	0.7734
Out	8.1018
Nov	-0.1936
Dez	-1.9511
Jan	3.3566
Fev	-8.0278
Mar	0.6269
Abr	-4.3639
Mai	-3.0734

Fonte: Autor (2020)

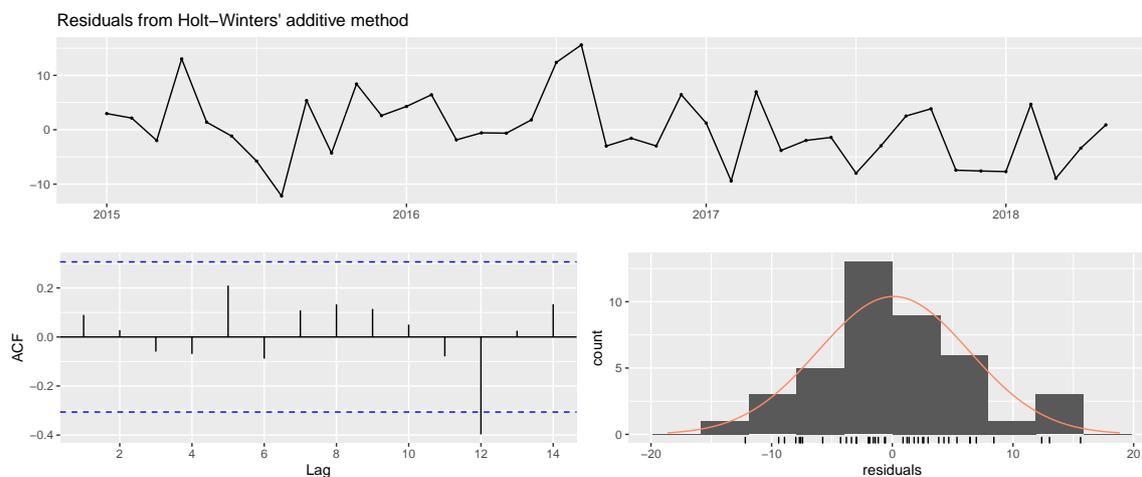
Diferente dos modelos ARIMA, na classe de modelos de suavização as estimativas dos parâmetros apresentados na Tabela 4.5 são adicionados ou subtraídos na previsão para que a sazonalidade seja incorporada. Já a adequabilidade do modelo é analisada conforme apresentado anteriormente no modelo AR(2) de Box & Jenkins.

Inicialmente faremos uma análise visual dos resíduos do modelo HWA ajustado, Figura 4.7. Esta análise foi complementada a partir da aplicação de testes estatísticos como mostra a Tabela 4.6.

Tabela 4.6. Testes de resíduos - ruídos brancos

Testes	p-valor
Ljung-Box	0.5501
Box-Pierce	0.5643
Shapiro-Wilk	0.6776
Jarque-Bera	0.6024

Fonte: Autor (2020)

Figura 4.7. Análise dos resíduos do modelo ajustado de Holt-Winters Aditivo.

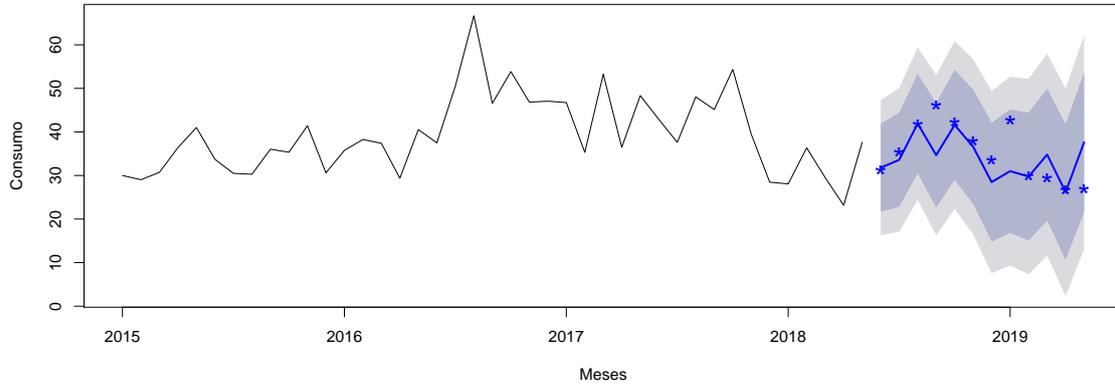
Fonte: Autor (2020)

À partir da Figura 4.7 e da Tabela 4.6, podemos verificar que o modelo está bem ajustado e que todos os pressupostos foram observados ao nível de 5% de significância.

Em conjunto com a análise de resíduos, consideramos o cálculo de ME e RMSE, respectivamente iguais a 0.1053 e 6.1714. O que fornece uma falta mensal média de medicamentos inferior à apresentada no modelo de Box & Jenkins com erros mais homogêneos/uniformes. Assim, a escassez e o excesso de medicamentos se mostram mais controlados, no entanto, também é esperado que os dados de teste (previsão) possuam maiores desvios.

Como a análise de resíduos e as medidas de erros apresentadas sugerem que o modelo Aditivo de Holt-Winters se ajusta bem aos dados observados, a Figura 4.8 apresenta a previsão da demanda futura, do medicamento oncológico, pelo modelo.

Figura 4.8. Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado Holt-Winters Aditivo comparada com a demanda observada.



Fonte: Autor (2020)

4.3.2 Ajuste do modelo de Holt-Winters multiplicativo

Similar ao modelo aditivo de Holt-Winters (HWA), o modelo multiplicativo de Holt-Winters (HWM) ajustado é representado nas equações 4.5, 4.6, 4.7 e 4.8.

$$l_t = 0.3692 \frac{y_t}{s_{t-m}} + (1 - 0.3692)(l_{t-1} + b_{t-1}) \quad (4.5)$$

$$b_t = 0.0312(l_t - l_{t-1}) + (1 - 0.0312)b_{t-1} \quad (4.6)$$

$$s_t = 2e^{-4} \frac{y_t}{l_t} + (1 - 2e^{-4})s_{t-s} \quad (4.7)$$

$$\hat{y}_{t+h|t} = (l_t + b_t m) + s_{t-s+m} \quad (4.8)$$

Os valores iniciais para l , b são $l_0 = 30.6697$ e $b_0 = 0.7839$, respectivamente. As constantes periódicas da variável sazonal, s são apresentadas na Tabela 4.7 que segue.

Diferente dos modelos de suavização aditivos, aqui os valores dos parâmetros apresentados na Tabela 4.5 são multiplicados (e não adicionados ou subtraídos) na previsão para que a sazonalidade seja incorporada. A adequabilidade do modelo é analisada conforme apresentado anteriormente nos modelos AR(2) e HWA.

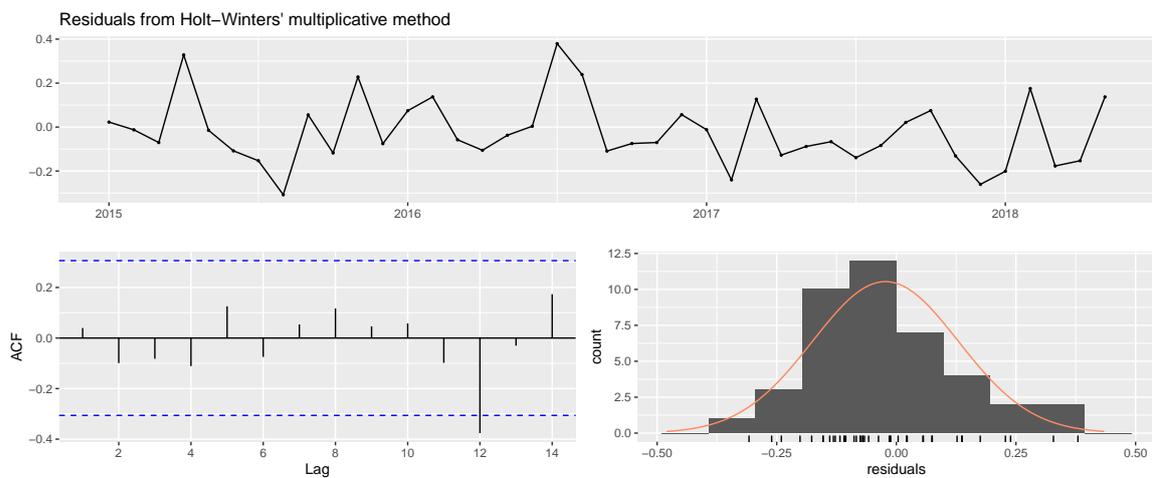
Novamente faremos uma análise visual dos resíduos do modelo HWM ajustado, Figura 4.9. Esta análise foi complementada a partir da aplicação de testes esta-

Tabela 4.7. Parâmetros sazonais iniciais (s)

Mês	Parâmetro
Jun	0.9131
Jul	1.0239
Ago	1.1734
Set	1.0339
Out	1.1876
Nov	0.9405
Dez	0.9715
Jan	1.093
Fev	0.8299
Mar	0.9969
Abr	0.9038
Mai	0.9326

Fonte: Autor (2020)

tísticos como mostra a Tabela 4.8.

Figura 4.9. Análise dos resíduos do modelo ajustado de Holt-Winters multiplicativo.

Fonte: Autor (2020)

Tabela 4.8. Testes de resíduos - ruídos brancos

Testes	p-valor
Ljung-Box	0.7930
Box-Pierce	0.8002
Shapiro-Wilk	0.1568
Jarque-Bera	0.1881

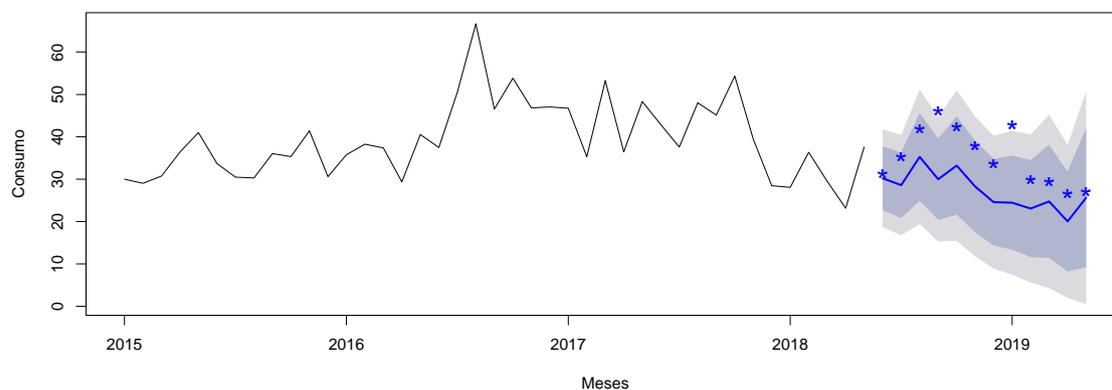
Fonte: Autor (2020)

À partir da Figura 4.9 e da Tabela 4.8, podemos verificar que o modelo está bem ajustado (é uma série de ruído branco) e que todos os pressupostos foram observados ao nível de 5% de significância.

Em conjunto com a análise resíduos, consideramos o cálculo de ME e RMSE, respectivamente iguais a -1.14752 e 5.98755 . O que fornece um excesso de medicamentos para os dados de treinamento com erros ainda mais homogêneos/uniformes. No entanto, assim como os outros modelos, é esperado que os dados de teste (previsão) possuam maiores desvios.

Como a análise de resíduos e o as medidas de erros apresentadas sugerem que o modelo multiplicativo de Holt-Winters se ajusta bem aos dados observados, a Figura 4.10 apresenta a previsão da demanda futura do medicamento oncológico pelo modelo.

Figura 4.10. Previsão de demanda pontual e intervalar (90 e 95% de confiança) para o modelo ajustado Holt-Winters Multiplicativo comparado com a demanda observada.



Fonte: Autor (2020)

4.4 Comparação dos modelos

Afim de comparar e selecionar apenas um modelo para a previsão de demanda, vamos começar analisando os erros destes modelos. Erros são medidas de acuracidade e quanto menor seu valor, em módulo, mais equiparada a previsão em relação a demanda real. A Tabela 4.9 evidencia que o modelo de Holt-Winters aditivo é o mais adequado em termos de ME e RMSE, em relação aos dados da série de teste, que como mencionado, possui medida de erros similares ou superiores as anteriores.

Medicamentos oncológicos são administrados em pessoas em estado crítico, o que justifica a escolha do objetivo estratégico dessas organizações ser, em sua maioria, a confiabilidade. O viés de previsão, representado pelo valor do erro médio, indica

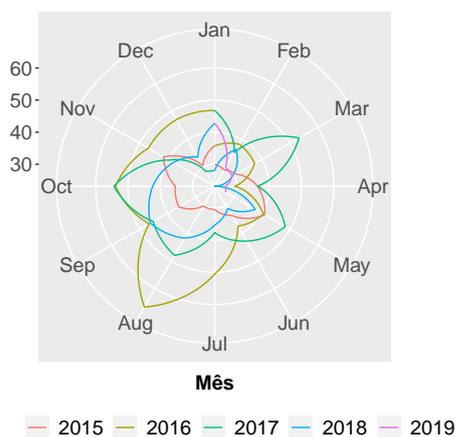
Tabela 4.9. Análise da acurácia dos modelos estimados.

Modelo	ME	RMSE
Box & Jenkins	3.33893	7.09208
Aditivo	1.32686	6.08581
Multiplicativo	7.98951	9.37947

Fonte: Autor (2020)

uma sub-previsão em todos os modelos, no entanto com valores muito superior para Holt-Winter multiplicativo, o que justifica a rejeição do modelo.

Como complemento, a Figura 4.11 apresenta o gráfico para análise de sazonalidade do modelo.

Figura 4.11. Gráfico de sazonalidade.

Fonte: Autor (2020)

Apesar de existir uma sazonalidade, esta é fraca e poderia ser rejeitada se analisássemos apenas a Figura 4.11. Porém, ao analisar a série original, Figura 3.1 podemos verificar que existe uma sazonalidade uma vez que o consumo se altera de tempos em tempos, o que fundamenta uma maior assertividade ao modelo de Holt-Winters aditivo.

Não vamos nos pautar apenas nos erros e na presença de sazonalidade, outra forma de seleção (comparação) dos modelos é por meio dos erros e previsões, período a período, dos modelos Box & Jenkins e aditivos de Holt-Winters com os valores reais observados, como mostra a Tabela 4.10.

Os erros de previsão do modelo aditivo são usualmente inferiores. Além disso, a presença de sazonalidade naturalmente torna inadequado o modelo de Box & Jenkins,

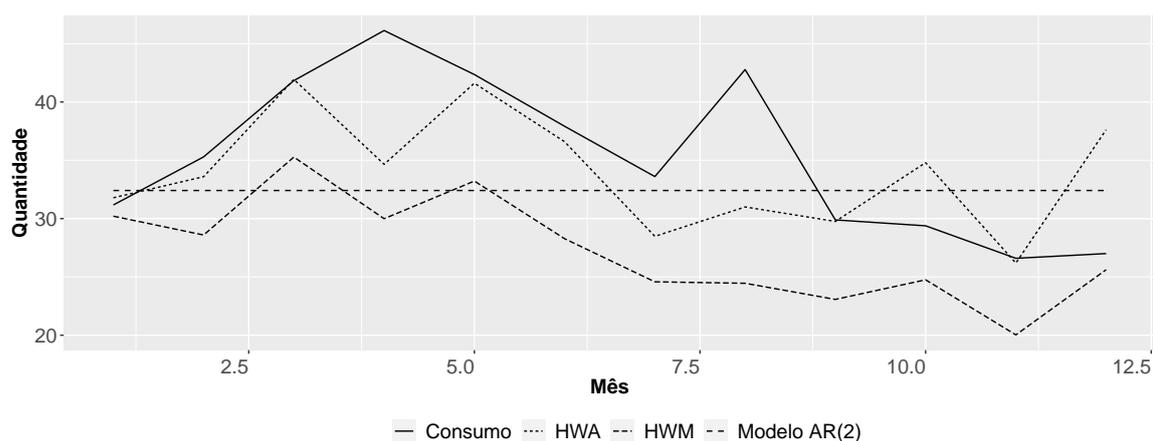
Tabela 4.10. Previsões de consumo para os modelos Box & Jenkins e Holt-Winters aditivo.

Mês	Valores Reais	Previsão		Erros	
		Box & Jenkins	Holt-Winters	Box & Jenkins	Holt-Winters
Jun	31.1700	32.40869	31.78643	-1.23869	-0.61643
Jul	35.2900	32.40869	33.59163	2.88131	1.69837
Aug	41.8325	32.40869	41.93502	9.42381	-0.10252
Sep	46.1275	32.40869	34.65495	13.71881	11.47255
Oct	42.3525	32.40869	41.61161	9.94381	0.74089
Nov	37.9150	32.40869	36.59111	5.50631	1.32389
Dec	33.6013	32.40869	28.47802	1.19261	5.12328
Jan	42.7776	32.40869	30.99898	10.36891	11.77862
Feb	29.8876	32.40869	29.75654	2.52109	0.13106
Mar	29.3813	32.40869	34.79419	-3.02739	-5.41289
Apr	26.5939	32.40869	26.18842	-5.81479	0.40548
May	27.0001	32.40869	37.62009	-5.40859	-10.61999

Fonte: Autor (2020)

apesar deste apresentar erros inferiores em 33.33% dos períodos. A excelência para as organizações com critérios voltados para confiabilidade, deve ser pautada nos modelos mais assertivos (Holt-Winters Aditivo obteve desempenho superior em %66,67 dos mês previstos). A Figura 4.12 apresenta uma análise visual desta previsão.

Figura 4.12. Série de consumo prevista pelos modelos.



Fonte: Autor (2020)

De forma geral o modelo multiplicativo traz previsões constantemente inferiores aos valores reais e o modelo de Box & Jenkins retorna valores fixos que não

se mostram vantajosos devido a sazonalidade dos dados. Já o modelo aditivo se confirma apto, dentre os modelos de Box-Jenkins e variações da suavização exponencial estudada, ao originar sub e super-previsões na busca pelo ajuste ideal.

Os modelos rejeitados são justificados pelo mau desempenho que provocaria, na maior parte do horizonte de previsão, com sub dimensionamento e consequentemente o comprometimento de parcela dos aproximadamente mil (1000) atendimentos realizados mensalmente, considerando as aplicações dos 163 medicamentos do setor oncológico. Discutiremos mais sobre o impacto da previsão de demanda proposta na gestão de estoque no a seguir no tópico 4.5.

4.5 Análise de Estoque

Em campo, sabemos que a incerteza e a complexidade relacionadas à demanda do produto, impõem que grandes níveis de estoques sejam imprescindíveis para as empresas. Políticas de gestão de estoque acertivas são fundamentais para o aumento da lucratividade em mercados competitivos, possibilitando um equilíbrio entre benefícios e malefícios desses estoques Das et al. (2012).

Uma política eficiente de gestão de estoque conta com a determinação da importância dos itens em relação as operações de estocagem da empresa, sendo a curva ABC uma ferramenta eficaz para este tipo de classificação, de acordo com os valores e volume de cada item. Ele assume que uma menor quantidade de itens possui grande parte do valor percebido, sendo eficaz controlar diferentes categorias de produtos por diferentes métodos, possibilitando a diferenciação no tratamento dos itens em estoque Giancesi e de Biazzi (2011); Eraslan e İÇ (2019).

Karagiannis (2018) propuseram uma variação no modo de classificação dos itens mas, apesar da alternativa proposta, nesse trabalho empregamos a lógica tradicional que utiliza valores e volume para priorização dos medicamentos em estoque. Assumimos que os medicamentos com maior representatividade monetária requerem um método de previsão individual enquanto, os itens com menor representatividade podem ser estimados por previsões agregadas. Feito isso, o medicamento com maior expressividade monetária em estoque foi objeto principal desse trabalho.

Evidências quanto à discrepâncias entre a quantidade disponibilizada pelo su-

primento e o consumo do medicamento indicaram o super dimensionamento do estoque (Figura 4.3) demonstrando a necessidade da empresa de alinhar os objetivos, permitindo que a gestão de estoque atue sobre o processo de suprimento. Basicamente, a empresa precisa decidir quanto ao que, em que e quando suprir já que pouca ação normalmente pode ser feita sobre o processo de demanda Giansesi e de Biazzi (2011).

Definir o que suprir requer três informações: estoque inicial, demanda e estoque final. O estoque inicial é dependente da acurácia de estoque das empresas, que não se aplica nesse trabalho, visto que nosso nível de acurácia é maior que 99%, conforme já citado anteriormente; a demanda advém dos métodos de previsão condizentes com comportamento dos dados, conforme capítulo 4.4; o estoque final desejado depende do objetivo do processo de gestão de estoque.

Três objetivos são comumente utilizados na gestão de estoque empresariais: nível de atendimento, custos e a eficiência da gestão de suprimentos. A consequência direta no estoque final é, respectivamente: (i) estoque de segurança como nível de estoque final para o aumento da probabilidade de atendimento da demanda; (ii) menor nível de estoque possível para que possibilite a redução dos custos; (iii) nível de estoque condizendo com o menor custo operacional possível Giansesi e de Biazzi (2011).

Dentre os três objetivos citados, as organizações de cuidado a saúde almejam um alto nível de atendimento Syntetos et al. (2015); Kourentzes et al. (2019); Buschiazzi et al. (2020); Uthayakumar e Priyan (2013), ver por exemplo. Também é um consenso literatura, que esse objetivo precisa ser ponderado para que não comprometa demasiadamente a saúde financeira da empresa, dado aos altos custos de estoque e operação.

O modelo de Holt-Winters Aditivo atingiu um nível satisfatório de 95% de confiança nas previsões mensais geradas, no entanto, em alguns momentos é identificado o sub-dimensionamento da demanda, conforme Figura 4.8. Dado isso, calculamos o estoque de segurança, conforme Uthayakumar e Priyan (2013) por intermédio da equação 4.9.

$$SS_i = k_i * \sigma_i * \sqrt{L}, \quad (4.9)$$

Em que, SS_i corresponde ao estoque de segurança do medicamento estudado, k_i o fator de segurança para o produto conforme valores tabelados, σ_i o desvio padrão da demanda durante um intervalo de tempo estabelecido, e L o *lead time* para que o

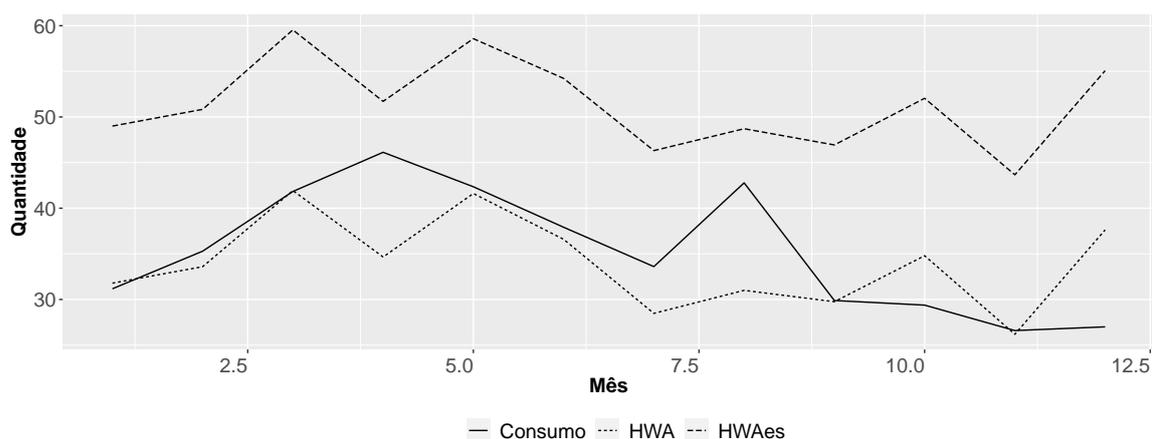
medicamento chegue até a empresa. Consideramos um fator de segurança de 90% (1,282), o desvio padrão de 6.5791 correspondente ao ano anterior a previsão, e *lead time* de quatro dias. Desse modo, tem-se um estoque de segurança de 16.8688 doses com níveis de estoques demonstrados na Tabela 4.11. A série de estoque de segurança pode ser comparada ao modelo de Holt-Winters Aditivo puro e os valores reais (Figura 4.13).

Tabela 4.11. Impacto do estoque de segurança ao modelo de Holt-Winters aditivo.

Mês	Consumo	Demanda Esperada		Balanço de Estoque		
		Holt-Winters	SS_i	Compra	Inicial	Final
Jun	31.1700	31.78643	16.86881	49.0000	49.0000	17.8300
Jul	35.2900	33.59163	16.86881	33.0000	50.8300	15.5400
Aug	41.8325	41.93502	16.86881	44.0000	59.5400	17.7075
Sep	46.1275	34.65495	16.86881	34.0000	51.7075	5.5800
Oct	42.3525	41.61161	16.86881	53.0000	58.5800	16.2275
Nov	37.9150	36.59111	16.86881	38.0000	54.2275	16.3125
Dec	33.6013	28.47802	16.86881	30.0000	46.3125	12.7112
Jan	42.7776	30.99898	16.86881	36.0000	48.7112	5.9336
Feb	29.8876	29.75654	16.86881	41.0000	46.9336	17.0460
Mar	29.3813	34.79419	16.86881	35.0000	52.0460	22.6647
Apr	26.5939	26.18842	16.86881	21.0000	43.6647	17.0708
May	27.0001	37.62009	16.86881	38.0000	55.0708	28.0707

Fonte: Autor (2020)

Figura 4.13. Efeito do Estoque de Segurança (HWAes).



Fonte: Autor (2020)

O acréscimo da quantidade de segurança determinada pode ser facilmente realizado conforme demonstrando na Tabela 4.11, o que resulta em um atendimento

total da demanda. Vale ressaltar que o valor do medicamento corresponde a aproximadamente quatro vezes e meia (4,5) o valor do salário mínimo e, portanto, enfrentamos um *trade off* novamente quanto ao atendimento total da demanda requerido e o custo de estoque organizacional.

Para análise mais aprofundada desse *trade off*, podemos utilizar outras ferramentas como os indicadores de desempenhos comumente aplicados na gestão de estoque. Dado os três principais objetivos das organizações e seus impactos sobre a gestão de estoque, os principais indicadores empregados para monitorá-los são: nível de serviço, giro de estoque e eficiência operacional, respectivamente, para cada objetivo citado anteriormente.

Nesse estudo de caso, destacamos brevemente a eficiência operacional da organização e assim, desenvolveremos os indicadores de giro de estoque e nível de serviço assumindo objetivo organizacional fundamentado em confiabilidade e custos.

O giro de estoque é comum às organizações devido sua simplicidade. Muito disso é devido à disponibilidade dos dados, já que os estoques são frequentemente controlados de forma detalhada, muitas vezes por meio de um sistema ERP, devido à imposições governamentais ou desejo de um bom gerenciamento do negócio. O indicador é dado pelo quociente da demanda anual sobre o investimento médio em estoque para o mesmo período de tempo, Ballou (2007), ou seja, a cobertura é dada pelo inverso do giro.

Os indicadores propostos, para verificação da efetividade da gestão de estoque, podem ser visualizados na Tabela 4.12. Para análise do nível de serviço, podemos trabalhar com o a cobertura média de estoque Buschiazzo et al. (2020).

Tabela 4.12. Indicadores de desempenho para a gestão de estoque.

Cenário	Giro de Estoque	Nível de Serviço	
		Cobertura de Estoque	Percentual atendido
Atual	5.312482	2.258831	100%
Est. Segurança	8.250009	1.454544	100%
Previsão	11.99862	1.000115	93.18%

Fonte: Autor (2020)

Valores obtidos pelo cálculo do giro de estoque indicam que, no cenário atual, o estoque é renovado aproximadamente 5,32 vezes durante um ano. Esse índice é maior para os cenários propostos: 8.25 e 12 vezes, para os cenários em que utilizamos

o método de previsão com e sem o estoque de segurança, respectivamente. Com um cenário mensal, em termos de custos, o ideal é a obtenção de um índice próximo a 12, que se traduz no consumo total dos itens comprados para o mês, destacando a previsão pelo método de Holt-Winters aditivo.

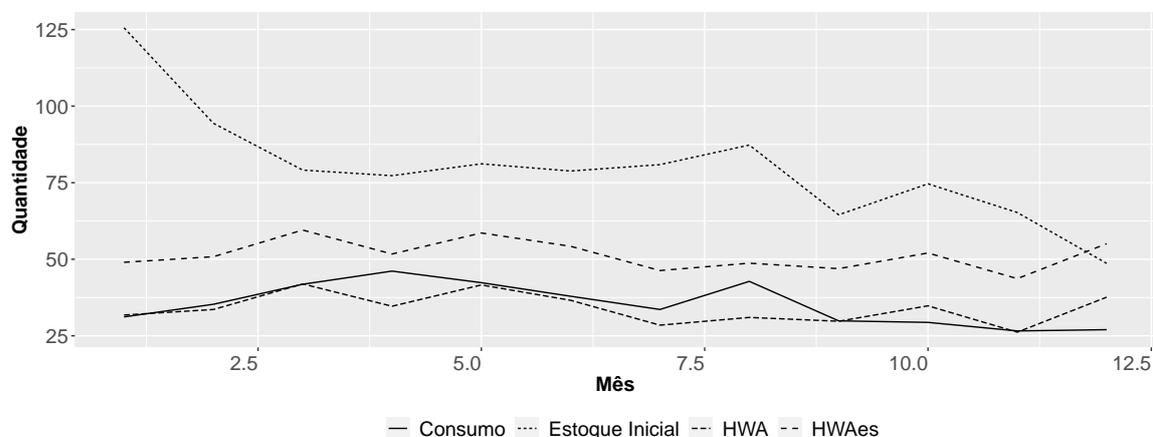
Consumir todo o estoque programado para o mês pode ser um indicativo de não atendimento total da demanda. Posto isto, consideramos um percentual de atendimento, calculado pelo índice de todos os pacientes atendidos durante o mês de sua demanda ponderado pela quantidade total de pacientes que requereram atendimento durante o mesmo período. Com o acréscimo do estoque de segurança o atendimento total da demanda é realizado, enquanto o método de previsão puro nos leva a um atendimento tardio ou não atendimento de 6.82% dos paciente. Devido a seriedade do tratamento oncológico esse é um fator preocupante.

O índice de cobertura de estoque maior que do que 1 indica que a quantidade disposta em estoque é suficiente para um período maior que um mês e, quando maior o valor nominal da cobertura do estoque, maior o indício de um super dimensionamento. Dado um valor médio de consumo, todos os cenários atenderiam a demanda real. Todavia a sazonalidade dos dados é desconsiderada, o que nos leva a desconsiderar a análise desse indicador.

Indicadores de giro de estoque e nível de serviço representam habilmente o *trade off* no processo de gerenciamento de estoques, medindo impactos sociais e financeiros. Sua importância é dada pelo fato de que quanto menor o giro de estoque, maior o tempo em que os medicamentos permanecerão imobilizados e, conseqüentemente, maior será o montante monetário aplicado pela organização. Por outro lado, quando maior o nível de serviço, maior a quantidade de pessoas que recebem tratamento em tempo hábil de recuperação. As duas métricas possuem interesses conflitantes e por isso devem ser ponderadas.

Independente do nível de ponderamento determinado, podemos acrescentar na análise gráfica (Figura 4.3) a série temporal prevista com e sem a complementação do estoque de segurança (Figura 4.14). Fica evidente os diferentes níveis de estoques iniciais e consumo de medicamentos. A discrepância entre as séries temporais apontam uma possível melhoria na saúde financeira da empresa, indiferente do acréscimo de segurança, dado um item de aproximadamente quadro salários mínimos e meio por unidade. Essas discrepâncias evidenciam a importância do respaldo metodológico citado por Jalalpour et al. (2015).

Figura 4.14. Estoques iniciais



Fonte: Autor (2020)

Divergências de quantidades apresentadas na Figura 4.14 multiplicadas pelo valor do item analisado representam um valor empregue no estoque de modo inoportuno. Esta economia posta em um único SKU (*Stock Keeping Unit*) tem potencial limitado, no entanto, aplicando a técnicas de previsões adequadas para os itens evidenciados na adaptação da curva ABC, dados os altos valores individuais, tem-se uma grande melhoria em custos por intermédio de uma economia potencial. A escolha da priorização tanto do giro de serviço (Holt-Winter Aditivo) ou nível de serviço (Holt-Winter Aditivo com completção do estoque de segurança) retornam melhorias significativas para a organização.

Ademais, o processo de melhoria por meio de uma melhor assertividade da demanda e conseqüente redução dos excessos em estoques (propostos nesse trabalho) proporcionam um melhor posicionamento ambiental para as organizações, visto que, o dimensionamento correto do volume de produtos necessários em estoque reduz o número de produtos descartados no meio ambiente por perda de validade. O que é ainda mais crítico se tratando da toxicidade dos quimioterápicos.

Finalmente, as melhorias no processo de gestão de estoque podem ser divididas em três categorias: (i) melhorias no processo de suprimento; (ii) melhorias no processo de gestão da demanda; (iii) melhorias no processo de gestão dos estoques, Gianesi e de Biazzini (2011). Para o primeiro caso temos ações relacionadas com confiabilidade de fornecimento e custos operacionais. Consideramos aqui, a existência prévia da avaliação de fornecedores e um tempo e custos operacionais mínimo devido a acordos externos.

Em segundo lugar, pode-se considerar o aprimoramento da previsão da demanda, procedimento realizado nesse trabalho por intermédio de modelos de previsão adequados. Por último, tem-se as ações quanto a diferentes tratamentos para itens com representatividade desiguais, demonstrado através da classificação segundo volume e valores de forma individualizada. As vantagens da aplicação de séries individuais são citadas por Wang e Petropoulos (2016).

Assim, esse trabalho percorreu duas das três dimensões propostas por Gianesi e de Biazzini (2011) para a melhoria na gestão de estoque, comprovando o exposto por Haslam et al. (2019); McConnell et al. (2017) que afirmam que melhorias em relação a custos podem advir do controle de medicamento, no setor farmacêutico, visto que são os responsáveis por grande parte dos gastos nas organizações de prestação de serviços à saúde.

Todo o exposto nessa seção comprova a conexão e importância entre o processo de previsão de demanda e gestão de estoque, assim como afirmado por Kourentzes et al. (2019). Em geral, analisados de maneira individual na literatura.

CAPÍTULO 5

CONCLUSÃO E PERSPECTIVAS FUTURAS

Com o objetivo de prever a demanda de medicamentos de alto custo da área de oncologia, esta pesquisa concentrou seus esforços no estudo e aplicação das metodologias de séries temporais. Modelos estatísticos usados para a previsão, além de mais robustos que a previsão empírica usualmente realizada por profissionais não especializados, permitiram uma maior precisão nas previsões com erros controlados e passíveis de mitigação.

Como contribuições, a utilização desse modelos faz com que o *trade-off* entre custo e disponibilidade de estoque seja melhor gerenciado, evitando sub e super dimensionamentos. Nesse estudo de caso, a transição do modelo de previsão pode poupar milhares de reais, dado o custo do medicamento de aproximadamente quatro vezes e meia o valor do salário mínimo brasileiro, amparando a sobrevivência da empresa e garantindo maior competitividade de mercado.

Todas as organização de prestação de serviços a saúde possuem suas particularidades e conseqüentemente, diferentes comportamentos em seus dados de estoque e consumo. No entanto, é esperado que os modelos aplicados aqui possam ser replicados em algum grau na área de gestão de estoque de medicamentos oncológicos de alto custo. Para mais, os resultados obtidos nesse estudo tendem à motivar outras organizações na implementação de métodos mais robustos de previsão.

A análise completa com o ajuste de três modelos de séries temporais, pertencem-

centes a duas classes distintas: Box & Jenkins e suavização exponencial foi apresentada nesse trabalho. O modelo de Holt-Winters aditivo se mostrou superior aos demais por ser capaz de ajustar tanto a sazonalidade, quanto o particular comportamento desta série de consumo. Ademais, a complementação do estoque de segurança é proposta caso a organização projete excelência em seu nível de serviço.

Indicadores como giro de estoque e nível de serviços foram utilizados para contrastar a utilização ou não do estoque de segurança no processo de previsão. Independente da escolha organizacional, melhorias nos custos seriam conseguidos. Dado o instertício de tempo para ressuprimento, a proposição de novos monitoramentos para que o giro de estoque seja priorizado sem comprometer o nível de serviço é uma alternativa que foge do escopo desse trabalho.

Futuramente podem ser analisados o consumo do mesmo medicamento em outras instituições a fim de propor um modelo geral. A formação de *clusters* quanto a similaridade entre os medicamentos que respondem a 20% dos custos em estoque, também pode facilitar o processo de previsão. Séries podem ser empregues aos *clusters* menos representativos para estimativa de orçamento.

Quanto a análise de séries temporais, uma continuação deste trabalho pode agregar covariáveis, ou seja, leve em consideração características ambientais e do paciente. Outra proposta a ser analisada é a utilização do novo método proposto, juntamente com uma análise qualitativa dos especialistas, identificando se a interferência humana gera benefícios quando utilizamos ferramentas correta de previsão.

Ademais, uma análise de fluxo de valor também pode ser incorporada para que melhorias nos métodos de gerenciamento caminhem junto com a simplificação dos processos organizacionais. Bem como um estudo completo da cadeia de suprimentos agregaria no mesmo sentido.

Por fim, uma limitação deste estudo é a dependência da atualização do banco de dados por parte da organização prestadora de serviços a saúde para que fosse possível a validação de todos os modelos com dados mais recentes.

CAPÍTULO 6

AGRADECIMENTOS

Agradecemos à Capes pelo suporte financeiro.

REFERÊNCIAS BIBLIOGRÁFICAS

- Keith William Hipel, Angus Ian McLeod, e William C Lennox. Advances in box-jenkins modeling: 1. model construction. *Water Resources Research*, 13(3):567–575, 1977.
- GEP Box, GM Jenkins, e GC Reinsel. *Time series analysis, forecasting and control*. Englewood Clifs. NJ: Prentice-Hall, 1994.
- Rachel JC Chen, Peter Bloomfield, e Frederick W Cabbage. Comparing forecasting models in tourism. *Journal of Hospitality & Tourism Research*, 32(1):3–21, 2008.
- Spyros Makridakis, Steven C Wheelwright, e Rob J Hyndman. *Forecasting methods and applications*. John wiley & sons, 2008.
- Mônica Vinhas de Souza, Bárbara Corrêa Krug, Paulo Dornelles Picon, e Ida Vanessa Doederlein Schwartz. Medicamentos de alto custo para doenças raras no brasil: o exemplo das doenças lisossômicas. *Ciência & saúde coletiva*, 15:3443–3454, 2010.
- Hongwei Wang, Shuang Chen, e Yong Xie. An rfid-based digital warehouse management system in the tobacco industry: a case study. *International Journal of Production Research*, 48(9):2513–2548, 2010.
- Nornadiah Mohd Razali, Yap Bee Wah, et al. Power comparisons of shapiro-wilk, kolmogorov-smirnov, lilliefors and anderson-darling tests. *Journal of statistical modeling and analytics*, 2(1):21–33, 2011.
- Debasis Das, Mohuya B Kar, Arindam Roy, e Samarjit Kar. Two-warehouse production model for deteriorating inventory items with stock-dependent demand under inflation

- over a random planning horizon. *Central European Journal of Operations Research*, 20(2):251–280, 2012.
- Fotios Petropoulos, Spyros Makridakis, Vassilios Assimakopoulos, e Konstantinos Nikolopoulos. ‘horses for courses’ in demand forecasting. *European Journal of Operational Research*, 237(1):152–163, 2014.
- George EP Box, Gwilym M Jenkins, Gregory C Reinsel, e Greta M Ljung. *Time series analysis: forecasting and control*. John Wiley & Sons, 2015.
- Daniel A Goldstein, Qiushi Chen, Turgay Ayer, David H Howard, Joseph Lipscomb, Bassel F El-Rayes, e Christopher R Flowers. First-and second-line bevacizumab in addition to chemotherapy for metastatic colorectal cancer: a united states-based cost-effectiveness analysis. *Journal of Clinical Oncology*, 33(10):1112, 2015.
- Mehdi Jalalpour, Yulia Gel, e Scott Levin. Forecasting demand for health services: Development of a publicly available toolbox. *Operations Research for Health Care*, 5:1–9, 2015.
- Aris A Syntetos, M Zied Babai, e Everette S Gardner Jr. Forecasting intermittent inventory demands: simple parametric methods vs. bootstrapping. *Journal of Business Research*, 68(8):1746–1752, 2015.
- Shengnan Wang, Max Petzold, Junshan Cao, Yue Zhang, e Weibing Wang. Direct medical costs of hospitalizations for cardiovascular diseases in shanghai, china: trends and projections. *Medicine*, 94(20), 2015.
- Vedik Basetti, Ashwani K Chandel, e Rajeevan Chandel. Power system dynamic state estimation using prediction based evolutionary technique. *Energy*, 107:29–47, 2016.
- Christoph Bergmeir, Rob J Hyndman, e José M Benítez. Bagging exponential smoothing methods using stl decomposition and box-cox transformation. *International journal of forecasting*, 32(2):303–312, 2016.
- Konstantinos Nikolopoulos, Samantha Buxton, Marwan Khammash, e Philip Stern. Forecasting branded and generic pharmaceuticals. *International Journal of Forecasting*, 32(2):344–357, 2016.
- Monica S Ruiz, Allison O’Rourke, e Sean T Allen. Impact evaluation of a policy intervention for hiv prevention in washington, dc. *AIDS and Behavior*, 20(1):22–28, 2016.

- Liljana Ferbar Tratar, Blaž Mojškerc, e Aleš Toman. Demand forecasting with four-parameter exponential smoothing. *International journal of production economics*, 181:162–173, 2016.
- Karen J McConnell, Oscar E Guzman, Nisha Pherwani, Dustin D Spencer, Jennifer D Van Cura, e Katherine M Shea. Operational and clinical strategies to address drug cost containment in the acute care setting. *Pharmacotherapy: The Journal of Human Pharmacology and Drug Therapy*, 37(1):25–35, 2017.
- Zhang Yang, Li Ce, e Li Lian. Electricity price forecasting by a hybrid model, combining wavelet transform, arma and kernel-based extreme learning machine methods. *Applied Energy*, 190:291–305, 2017.
- Yves R Sagaert, El-Houssaine Aghezzaf, Nikolaos Kourentzes, e Bram Desmet. Tactical sales forecasting using a very large set of macroeconomic indicators. *European Journal of Operational Research*, 264(2):558–569, 2018.
- Bahareh Aghababaei, Mir Saman Pishvaei, e Farnaz Barzinpour. A two-stage fuzzy optimization model for scarce drugs supply and ration planning under uncertainty: A case study. *Applied Soft Computing*, 81:105514, 2019.
- Jennifer S Albrecht, Emerson M Wickwire, Aparna Vadlamani, Steven M Scharf, e Sarah E Tom. Trends in insomnia diagnosis and treatment among medicare beneficiaries, 2006–2013. *The American Journal of Geriatric Psychiatry*, 27(3):301–309, 2019.
- Alyson Haslam, Tyler Crain, Jennifer Gill, Diana Herrera-Perez, e Vinay Prasad. Where does the blame for high health care costs go? an empirical analysis of newspaper and journal articles criticizing health care costs. *The American journal of medicine*, 132(6):718–721, 2019.
- Nikolaos Kourentzes, Juan R Trapero, e Devon K Barrow. Optimising forecasting models for inventory planning. *International Journal of Production Economics*, page 107597, 2019.
- Spyros Makridakis, Rob J Hyndman, e Fotios Petropoulos. Forecasting in social settings: the state of the art. *International Journal of Forecasting*, 2019.
- Antonio Rafael Sabino Parmezan, Vinicius MA Souza, e Gustavo EAPA Batista. Evaluation of statistical and machine learning models for time series prediction: Identifying

- the state-of-the-art and the best conditions for the use of each model. *Information Sciences*, 484:302–337, 2019.
- M Buschiazzo, J Mula, e F Campuzano-Bolarin. Simulation optimization for the inventory management of healthcare supplies. *International Journal of Simulation Modelling (IJSIMM)*, 19(2), 2020.
- Marina Morgado Garcia, Pamela Santos Azevedo, Andrew Mirelman, Leandro Pinheiro Safatle, Roberto Iunes, Marion Clark Bennie, Brian Godman, e Augusto Afonso Guerra Junior. Funding and service organization to achieve universal health coverage for medicines: An economic evaluation of the best investment and service organization for the brazilian scenario. *Frontiers in pharmacology*, 11:370, 2020.
- Sha Zhu, Willem van Jaarsveld, e Rommert Dekker. Spare parts inventory control based on maintenance planning. *Reliability Engineering & System Safety*, 193:106600, 2020.
- Anwar Ul Haq, Adnan Zeb, Zhenfeng Lei, e Defu Zhang. Forecasting daily stock trend using multi-filter feature selection and deep learning. *Expert Systems with Applications*, 168:114444, 2021.
- Eugene Litvak e Michael C Long. Cost and quality under managed care: Irreconcilable differences. *Am J Manag Care*, 6(3):305–12, 2000.
- Pedro A Morettin e Clélia Tolo. *Análise de séries temporais*. 2006.
- Irineu Gustavo Nogueira Giansesi e Jorge Luiz de Biazzzi. Gestão estratégica dos estoques. *Revista de Administração*, 46(3):290–304, 2011.
- Cleber Cristiano Prodanov e Ernani Cesar de Freitas. *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição*. Editora Feevale, 2013.
- R Uthayakumar e S Priyan. Pharmaceutical supply chain and inventory management strategies: Optimization for a pharmaceutical company and a hospital. *Operations Research for Health Care*, 2(3):52–64, 2013.
- Rosa Maria Villares de Souza Berto e Davi Nakano. Revisitando a produção científica nos anais do encontro nacional de engenharia de produção. *Production*, 24(1):225–232, 2014.

- Xun Wang e Fotios Petropoulos. To select or to combine? the inventory performance of model and expert forecasts. *International Journal of Production Research*, 54(17): 5271–5282, 2016.
- Dietmar Meyer e Adela Shera. The impact of remittances on economic growth: An econometric model. *Economía*, 18(2):147–155, 2017.
- Rob J Hyndman e George Athanasopoulos. *Forecasting: principles and practice*. OTexts, 2018.
- Jennifer R Ledford e David L Gast. *Single case research methodology: Applications in special education and behavioral sciences*. Routledge, 2018.
- Erick Meira de Oliveira e Fernando Luiz Cyrino Oliveira. Forecasting mid-long term electric energy consumption through bagging arima and exponential smoothing methods. *Energy*, 144:776–788, 2018.
- Ergün Eraslan e Yusuf Tansel İÇ. An improved decision support system for abc inventory classification. *Evolving Systems*, pages 1–14, 2019.
- Ronald H Ballou. *Business logistics/supply chain management: planning, organizing, and controlling the supply chain*. Pearson Education India, 2007.
- Robert Goodell Brown. *Statistical forecasting for inventory control*. McGraw/Hill, 1959.
- Wayne A Fuller. *Introduction to statistical time series*, volume 428. John Wiley & Sons, 2009.
- M Goozner. Drug firms and insurers move to center stage in the cost debate. *Modern healthcare*, 45(8):26, 2015.
- Giannis Karagiannis. Partial average cross-weight evaluation for abc inventory classification. *International Transactions in Operational Research*, 2018.
- Samuel Karlin. *A first course in stochastic processes*. Academic press, 2014.
- Greta M Ljung. Diagnostic testing of univariate time series models. *Biometrika*, 73(3): 725–730, 1986.
- Paulo Augusto Cauchick Miguel. Estudo de caso na engenharia de produção: estruturação e recomendações para sua condução. *Production*, 17(1):216–229, 2007.

R Core Team. *R: A Language and Environment for Statistical Computing*. R Foundation for Statistical Computing, Vienna, Austria, 2020. URL <http://www.R-project.org/>.

Robert K Yin. *Estudo de Caso-: Planejamento e métodos*. Bookman editora, 2015.