UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE GESTÃO
ADMINISTRAÇÃO

ANDERSON DE ARAÚJO SOARES

ANÁLISE COMPARATIVA DE SÉRIES TEMPORAIS PARA DETERMINAÇÃO DE UM MODELO DE PREVISÃO DA DEMANDA EM UMA INDÚSTRIA TÊXTIL

CARUARU
2017

UNIVERSIDADE FEDERAL DE PERNAMBUCO
CENTRO ACADÊMICO DO AGRESTE
NÚCLEO DE GESTÃO
ADMINISTRAÇÃO

ANDERSON DE ARAÚJO SOARES

ANÁLISE COMPARATIVA DE SÉRIES TEMPORAIS PARA DETERMINAÇÃO DE UM MODELO DE PREVISÃO DA DEMANDA EM UMA INDÚSTRIA TÊXTIL

Trabalho apresentado à Coordenação do Curso de Graduação em Administração, da Universidade Federal de Pernambuco, Centro Acadêmico do Agreste, como requisito parcial para aprovação na disciplina Trabalho de Conclusão de Curso.
Orientador: Prof. M.Sc. José Cícero de Castro.

CARUARU
2017

Catalogação na fonte:
Bibliotecária – Simone Xavier CRB/4 - 1242

S676a Soares, Anderson de Araujo.
Análise comparativa de séries temporais para determinação de um modelo de previsão de demanda em uma indústria têxtil. / Anderson de Araujo Soares. – 2017.
74f. : 30 cm.

Orientadora: José Cícero de Castro.
Monografia (Trabalho de Conclusão de Curso) – Universidade Federal de Pernambuco, CAA, Administração, 2017.
Inclui Referências.

1. Controle de estoque. 2. Séries temporais. 3. Demanda. I. Castro, José Cícero de (Orientador). II. Título.

658 CDD (23. ed.) UFPE (CAA 2017-441)

ATA DE DEFESA DO TRABALHO DE CONCLUSÃO DE CURSO EM ADMINISTRAÇÃO NO CAMPUS DO AGRESTE

Às 17 horas do dia 15 do mês de dezembro do ano de 2017, na sala 9 do bloco O da UFPE/CAA, compareceram para defesa pública do Trabalho de Conclusão de Curso, requisito obrigatório para a obtenção do título de BACHAREL EM ADMINISTRAÇÃO o aluno: Anderson de Araújo Soares tendo como Título do Trabalho de Conclusão de Curso: Análise comparativa de séries temporais para determinação de um modelo de previsão da demanda em uma indústria têxtil. Constituíram a Banca Examinadora os professores: professor José Cícero de Castro (orientador), professora Alane Alves Silva (examinadora), professor Marcos Luiz Henrique (examinador), e professora Tatiana Balbi Fraga (examinadora). Após a apresentação e as observações dos membros da banca avaliadora, ficou definido que o trabalho foi considerado _____ (aprovado ou reprovado) com conceito_____ (0 a 10 pontos).

Eu, _____ (Orientador), lavrei a presente ata que segue assinada por mim e pelos demais membros da Banca Examinadora.

Observações:_____

_____

_____

_____

Assinaturas:

Membros da Banca Examinadora:

_____

Prof. M.Sc. José Cícero de Castro

Orientador

_____

Profª. Dra. Alane Alves Silva

Examinadora

_____

Prof. Marcos Luiz Henrique

Examinador

_____

Profª. Dra. Tatiana Balbi Fraga

Examinadora

AGRADECIMENTOS

Agradeço a Jeová, por ter me concedido a oportunidade de estudar em uma universidade pública, bem como ter me dado forças percorrer toda a jornada da graduação.

Agradeço a minha esposa e filhos por entenderem os momentos de ausência.

Agradeço aos meus pais pelo incentivo e a cobrança insistente da minha mãe para a conclusão deste trabalho.

Agradeço ao meu irmão Júnior por toda a sua dedicação, ajuda e incentivo para a elaboração desta monografia, a sua ajuda foi imprescindível. Obrigado!

Agradeço ao meu orientador, professor José Cícero de Castro, pela disponibilidade dispensada durante a construção do trabalho, pelo acompanhamento contínuo e sempre a busca pela excelência.

Agradeço ao professor Marcos Luiz pela ajuda no entendimento e aplicação dos modelos matemáticos.

Agradeço a empresa que me autorizou a realizar a pesquisa e fornecimento de dados.

Agradeço a todos que contribuíram de alguma forma durante a minha jornada acadêmica.

“O aluno não está acima do seu instrutor, mas todo aquele que for perfeitamente instruído será semelhante ao seu instrutor”.

Lucas 6:40 – Tradução do Novo Mundo da Bíblia Sagrada

RESUMO

Em busca cada vez mais de eficácia e eficiência em seus processos, as empresas buscam ferramentas que melhorem e aumente a sua produtividade. Talvez seja uma das máximas da administração, fazer mais com menos. O uso de métodos de previsão da demanda pode se tornar um grande aliado do administrador no seu planejamento. Esta obra tem como objetivo trazer um resumo dos principais métodos de previsão utilizados hodiernamente e elaborar uma análise comparativa com uma aplicação prática em dados históricos reais fornecidos pela empresa do estudo, que ocupa a segunda colocação entre os maiores fabricantes nacionais no seu segmento, empregando técnicas de séries temporais. Os resultados obtidos com a técnica de alisamento exponencial se mostraram bem melhores em comparação com o método utilizado atualmente pela empresa, a qual utiliza um modelo baseado na maior média dos três, seis ou doze últimos períodos, sem levar em consideração características da série, tais como: tendência e sazonalidade. Constatou-se que os métodos de suavização exponencial apresentaram os menores erros para a série estudada, e o modelo de Winter foi o mais adequado para realizar previsões, chegando a reduzir 88 pontos percentuais os níveis de estocagem e prevendo 77 pontos percentuais melhor do que o método que a organização adota como preditor de demanda.

Palavras-chave: Gestão de estoque. Previsão da demanda. Séries temporais. Alisamento exponencial.

ABSTRACT

In search of more and more effectiveness and efficiency in their processes, as companies look for tools that improve and increase their own productivity. Maybe she's one of the best in management, do more with less. Using demand forecasting methods can become a great ally of the administrator in your planning. This work aims to provide a summary of the main forecasting methods used through a comparative analysis with a practical application in real historical data proved by the study company, which occupies a second place among the largest national manufacturers, not its segment, employing time series techniques. The results obtained with the exponential smoothing technique were better in comparison to the method used by the company, a quality used in the main media of the three, six or twelve last periods, without taking into account series characteristics such as: trend and seasonality . It was verified that the exponential smoothing methods presented the smallest errors for a series studied, the winter model was the most suitable to make predictions, reaching to reduce 88 percentage points of storage levels and predicting 77 percentage points better than the method that an organization adopts as a predictor of demand.

Keywords: Inventory management. Demand forecast. Time series. Exponential smoothing

LISTA DE FIGURAS

Figura 2.1: Organograma da empresa 19
Figura 3.1: Custo da previsão versus custo da imprecisão 22
Figura 3.2: Operacionalização da técnica Delphi 28
Figura 5.1: Parâmetros no Solver utilizados para a otimização 46

LISTA DE QUADROS

Quadro 3.1: Métodos de previsão 25

LISTA DE TABELAS

Tabela 5.1: Modelagem da média móvel 44
Tabela 5.2: Otimização MAD 47
Tabela 5.3: Otimização MAPE 48
Tabela 5.4: Otimização MSE 49
Tabela 5.5: Otimização com Action Stat 50

LISTA DE ABREVIATURAS E SIGLAS

AES	Alisamento exponencial simples
BNDES	Banco Nacional de Desenvolvimento Econômico e Social
MAD	Mean Absolute Deviation
MAPE	Mean Absolute Percentual Error
MATLAB	MATrix LABoratory
MINITAB	Minitab Statistical Software
MPE	Mean Percentual Error
MSE	Mean Squared Error
MM3	Média móvel de 3 períodos
MM6	Média móvel de 6 períodos
MM12	Média móvel de 12 períodos
R	Linguagem e também um ambiente de desenvolvimento integrado para cálculos estatísticos e gráficos
SAFT	Self-Adaptative Forecasting Techinique
SPSS	Software estatístico da IBM
SQL	Structured Query Language
TI	Tecnologia da informação

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO 15
1.1 CONTEXTO E JUSTIFICATIVA 15
CAPÍTULO 2 - EMPRESA 18
2.1 INTRODUÇÃO 18
2.2 A EMPRESA OBJETO DE ESTUDO 18
2.2.1 Histórico 18
2.2.2 Missão 19
2.2.3 Visão 20
2.2.4 Princípios 20
CAPÍTULO 3 - REFERENCIAL TEÓRICO 21
3.1 INTRODUÇÃO 21
3.2 IMPORTÂNCIA DA PREVISÃO DA DEMANDA 21
3.3 CARACTERÍSTICAS DAS PREVISÕES 23
3.4 CARACTERÍSTICAS DA DEMANDA 23
3.5 MÉTODOS DE PREVISÃO 24
3.5.1 Métodos Qualitativos 25
3.5.1.1 Opiniões de Executivos 26
3.5.1.2 Opinião da Força de Vendas 26
3.5.1.3 Pesquisas Junto a Consumidores 27
3.5.1.4 Método Delphi 27
3.5.2 Métodos Causais 29
3.5.2.1 Regressão Linear Simples 29
3.5.2.2 Regressão Linear Múltipla 30
3.5.3 Métodos de Projeção Histórica 30
3.5.3.1 Média Móvel 31
3.5.3.2 Alisamento Exponencial Simples (AES) 32
3.5.3.3 Alisamento Exponencial Corrigido pela Tendência (Modelo de Holt) 33
3.5.3.4 Alisamento Exponencial Corrigido por Tendência e Sazonalidade (Modelo de Winter) 34
3.6 ERROS DE PREVISÃO 36

3.6.1 Mean Absolute Deviation (MAD) 36
3.6.2 Mean Absolute Percentual Error (MAPE) 36
3.6.3 Mean Squared Error (MSE) 37
3.6.4 Mean Percentual Error (MPE) 37
3.6.5 Sinal de Acompanhamento (SA) 37
3.7 OTIMIZAÇÃO DAS CONSTANTES DE ALISAMENTO 38
CAPÍTULO 4 - METODOLOGIA 40
4.1 INTRODUÇÃO 40
4.2 PROCEDIMENTOS METODOLÓGICOS 40
CAPÍTULO 5 - ANÁLISE DOS DADOS E DISCUSSÃO DOS RESULTADOS 42
5.1 INTRODUÇÃO 42
5.2 INICIATIVA 42
5.3 DEFINIÇÃO DO PROBLEMA 43
5.4 PREPARAÇÃO DOS DADOS 43
5.5 SOFTWARE 43
5.6 MODELO MATEMÁTICO 43
5.6.1 Média móvel 44
5.6.2 Alisamento Exponencial Simples (AES) 44
5.6.3 Alisamento Exponencial Corrigido pela Tendência (Modelo de Holt) 44
5.6.4 Alisamento Exponencial Corrigido por Tendência e Sazonalidade (Modelo Winter) 45
5.7 MEDIÇÃO DE ERRO 45
5.8 OTIMIZAÇÃO DAS CONSTANTES DE ALISAMENTO 45
5.9 CONSOLIDAÇÃO DOS RESULTADOS 46
5.9.1 Otimização MAD 47
5.9.2 Otimização MAPE 47
5.9.3 Otimização MSE 48
5.10 SOFTWARES DE PREVISÃO 49
CAPÍTULO 6 - CONCLUSÕES 51
6.1 INTRODUÇÃO 51
6.2 CONCLUSÕES 51
6.3 IMPLICAÇÕES GERENCIAIS 52
6.4 LIMITAÇÕES 52

6.5 SUGESTÕES DE TRABALHOS FUTUROS 53
REFERÊNCIAS 54
APÊNDICE A – Otimização MAD 56
APÊNDICE B – Otimização MAPE 61
APÊNDICE C – Otimização MSE 66
APÊNDICE D – Otimização utilizando o software Action Stat 71

CAPÍTULO 1 - INTRODUÇÃO

1.1 CONTEXTO E JUSTIFICATIVA

Na busca por mais eficiência e eficácia as empresas procuram aperfeiçoar cada vez mais suas operações, com a intenção de reduzir custos e otimizar recursos. Na indústria têxtil não é diferente, ainda mais com concorrência dos produtos importados, concorrência essa muitas vezes desleal, de produtos oriundos da Ásia, em especial chinesa que mantém os seus produtos com preços artificialmente baixos (GLOBO, 2017). Está atento às planilhas de custos, controle de estoques e operações são fatores imprescindíveis para sobrevivência da empresa.

O uso de métodos de previsão da demanda é um grande aliado para o planejamento da cadeia de suprimentos trazendo não só segurança no processo decisório, mas também redução de custos, contudo a falta de conhecimento dessas técnicas e a forma correta de escolhê-las e utilizá-las são um entrave para a adoção como ferramenta nas empresas, restando-lhes adotar o empirismo como principal forma de realizar previsões e de se planejarem, ficando a mercê muitas vezes, apenas de análises subjetivas de suas percepções de mercado, não que o *feeling* do administrador não seja importante, mas não deve ser a única opção quando técnicas mais modernas e assertivas estiverem disponíveis.

Pesquisas realizadas a respeito de previsão da demanda trouxeram benefícios significativos, como por exemplo a pesquisa realizada por (MEDEIROS, WINKELER, *et al.*, 2016) em uma subestação de distribuição de energia elétrica contribuiu para que os gestores pudessem realizar, com precisão, tomadas de decisão estratégicas importantes para o setor, como a compra de equipamentos, os projetos de expansão, a redução dos gastos com manutenções e o posicionamento no mercado de energia. Já o trabalho realizado por (JIANG, LIU e YUAN, 2017) com dados históricos de peças sobressalentes para caminhões pesados em uma companhia chinesa apontaram técnicas de previsão melhores que as adotadas pela empresa, trazendo assertividade para as previsões.

Essa pesquisa é motivada pela necessidade apontada pela gerência e direção da empresa em reduzir as rupturas de estoque, haja visto, que essas ocorrências de ruptura, trazem transtornos junto aos seus clientes pelo não cumprimento de contratos de fornecimento do seu produto. Também, é interesse da empresa a redução de estoques, pois o método utilizado atualmente a obriga a manter os níveis de estoque elevados, ocasionando um baixo giro de

estoque em vários itens e como consequência, uma parcela significativa do seu capital financeiro está alocado na estocagem de matéria prima.

O objetivo principal deste trabalho é identificar um modelo de previsão, dentre os existentes na literatura, por meio de uma análise comparativa que melhor produza estimativas para a empresa estudada, reduzindo o grau de incerteza e auxiliando na tomada de decisão, minimizando custos de estoques e rupturas do mesmo, descrevendo os detalhes dos modelos e posteriormente discutindo seus resultados. Ainda como objetivos a serem alcançados, destaca-se:

- Levantamento dos principais métodos de previsão da demanda utilizados atualmente;
- Levantamento de dados históricos para a aplicação dos métodos quantitativos de previsão da demanda;
- Definir modelo matemático de previsão de demanda com o menor erro de previsão com otimização das constantes de alisamento relacionadas à nível, tendência e sazonalidade;

Assim, este trabalho tem por finalidade abordar os principais métodos de previsão da demanda e aplicá-los em dados históricos da empresa com o propósito de encontrar o método que melhor preveja a demanda dado o comportamento da série de dados e compará-los com o sistema de previsão adotada atualmente pela empresa, fazendo uma confrontação de análise residual na medição dos erros.

Os resultados encontrados a partir dos dados existentes têm por objetivo melhorar a gestão da empresa com outros elos da cadeia de suprimentos e maximizar sua receita, dado que haverá um maior sincronismo entre oferta e demanda. Por outro lado, esta pesquisa além de um cunho notadamente gerencial procura contribuir para melhorar a qualidade da pesquisa na área de operações logística de empresas com características semelhantes e que atuam no mesmo setor industrial. Vale destacar a importância da pesquisa, pois ela está sendo feita numa empresa que ocupa a segunda colocação como maior fabricante no seu segmento.

Com os dados organizados, foram aplicados os modelos de séries temporais, seguindo as especificidades de cada um de acordo com a literatura, os resíduos foram tratados com a minimização dos erros de medição através da otimização das constantes de alisamento de cada método e por intermédio do sinal de acompanhamento deles, foi realizado uma comparação e o modelo de Winter apresentou os melhores resultados frente aos outros métodos e principalmente quando comparado com o sistema de previsão seguido pela empresa.

Para uma melhor ambientação do leitor o conteúdo desta monografia encontra-se organizada da seguinte maneira: o capítulo 1 apresenta o contexto e a justificativa da pesquisa,

o que pretende ser alcançado e como isso será feito, o capítulo 2 aborda um breve relato da empresa objeto de pesquisa, seu histórico, a sua missão, visão e princípios. No capítulo 3 é realizada uma revisão bibliográfica da literatura a respeito de previsão da demanda, suas características, métodos de previsão, medidas de erros e otimização das constantes de alisamento, já capítulo 4 apresenta os procedimentos metodológicos utilizados neste trabalho, no capítulo 5 é apresentada a análise dos dados, comparando-os e discutindo suas nuanças. O capítulo 6 traz a conclusão do TCC, implicações gerenciais, limitações e sugestões para estudos futuros. O capítulo 7, sendo este o último, apresenta as referências, indicando as fontes bibliográficas que fundamentaram a pesquisa. Após as referências, os apêndices.

CAPÍTULO 2 - EMPRESA

2.1 INTRODUÇÃO

Este capítulo traz uma breve descrição da empresa estudada.

2.2 A EMPRESA OBJETO DE ESTUDO

A empresa estudada neste trabalho está localizada no agreste central do estado de Pernambuco, é uma empresa do ramo têxtil. No seu segmento, ela se encontra na segunda colocação entres os maiores fabricantes do país. De acordo com a tabela divulgada no site do BNDES (Banco Nacional de Desenvolvimento Econômico e Social), pode ser classificada como média empresa, pois sua receita bruta anual está entre R$ 3,6 milhões e R$ 300 milhões (BNDES, 2017).

2.2.1 Histórico

A empresa foi criada em 1996 para atender as necessidades do polo de confecções do agreste, pois havia grande dificuldade para os pequenos produtores locais encomendarem pequenas partidas de etiquetas a empresas localizadas no sul e sudeste do país. Mas ao longo dos anos empreendeu um processo de crescimento contínuo e passou a atender várias outras regiões e hoje atua em praticamente todos os grandes centros de produção de confecções do país.

Atualmente a empresa dispõe de um parque fabril de implantado numa área de 34.100m², sendo 5.100 m² de área construída. Conta com o trabalho de colaboração de aproximadamente 405 funcionários que atendem aos pedidos de mais de 100 representantes comerciais que atuam nos principais polos confeccionistas do país.

A figura 2.1, ilustra o organograma da empresa.

Fonte: Cedido pela empresa, 2017

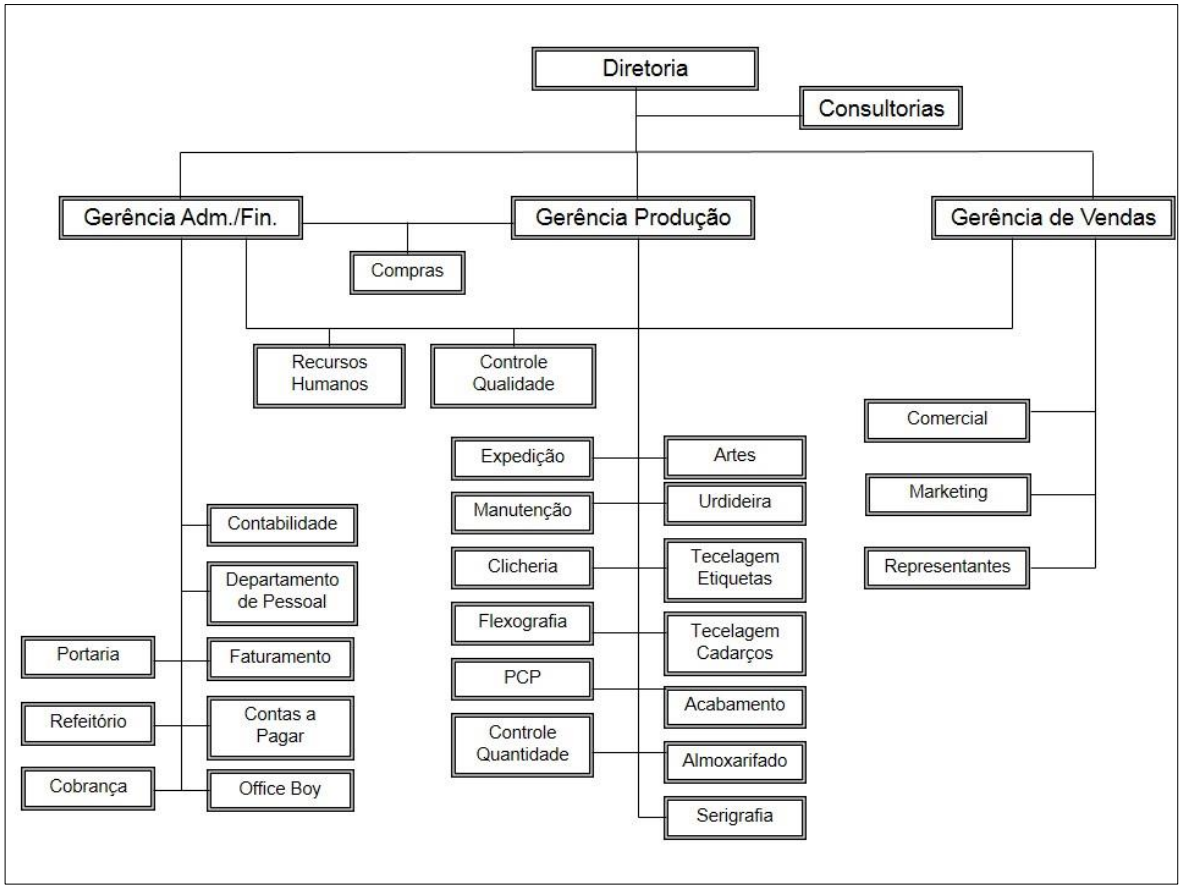

Figura 2.1: Organograma da empresa

O estudo foi realizado no departamento de gestão de estoques da empresa, no organograma refere-se ao departamento almoxarifado. Esse departamento é responsável pelas previsões de demanda. O departamento é formado por três colaboradores, sendo um encarregado, responsável pela gestão de estoque, e dois auxiliares.

2.2.2 Missão

Oferecer soluções personalizadas em etiquetas, valorizando a marca do cliente, com rentabilidade, em um ambiente que prima pelo crescimento profissional dos colaboradores com responsabilidade social.

2.2.3 Visão

Ser uma empresa rentável e reconhecida no mercado como símbolo de qualidade em produtos e serviços.

2.2.4 Princípios

Qualidade, profissionalismo, satisfação do cliente, credibilidade, crescimento e agilidade.

CAPÍTULO 3 - REFERENCIAL TEÓRICO

3.1 INTRODUÇÃO

Neste capítulo é realizada uma revisão bibliográfica de literatura sobre previsão de demanda, planejamento e métodos disponíveis.

3.2 IMPORTÂNCIA DA PREVISÃO DA DEMANDA

Para Chopra e Meindl (2016), as previsões da demanda formam a base de todo o planejamento da cadeia de suprimentos. Métodos de previsão auxiliam o gerente da cadeia de suprimentos a alocar de forma racional os recursos financeiros da organização. A previsão tem como base olhar para o passado, para tentar explicar o presente e prever o futuro, entre outros fatores, é um processo metodológico para determinação de dados futuros baseados em modelos estatísticos, matemáticos ou econométricos ou ainda modelos subjetivos (MARTINS e LAUGENI, 2005).

A função de um gestor, indiscutivelmente é tomar decisões, e para enfrentar os problemas do dia a dia, que muitas vezes surgem inesperadamente, ele precisa estar atento à obtenção, à análise e à transmissão de informações que sirvam de base ao processo decisório (QUEIROZ, HÉKIS, *et al.*, 2012). Realizar previsões reduzirá o grau de incerteza quantificando-a e o auxiliará na tomada de decisões, contribuindo para que a empresa, por exemplo, produza a quantidade adequada no momento oportuno, oferecendo maior acurácia na produção e adaptando-a as variações de mercado (MARTIN, HENNING, *et al.*, 2016).

Moreira (2008), afirma que a previsão da demanda é um processo racional de busca de informações acerca do valor das vendas futuras de um item ou de um conjunto de itens e, que profissionais de diversas áreas como, Marketing, Finanças e Produção tem interesse comum em previsões de longo prazo, envolvendo um ou outro aspecto do planejamento estratégico da empresa.

De acordo com Wanke e Julianelli (2011), praticamente todos os tipos de empresa, sejam elas de qualquer tamanho, pequeno, médio ou grande porte; estatais, nacionais privadas ou multinacionais, necessitam planejar seus recursos de produção, distribuição e aquisição de insumos ou serviços.

Bowersox *et al.* (2014, p. 127) argumenta que:

> A crescente complexidade das ofertas de produtos e táticas de marketing em conjunto com ciclos mais curtos de vida do produto requer maior acurácia, flexibilidade e consistência na determinação das necessidades de estoque. Os sistemas de gestão da demanda procuram oferecer essas capacidades.

O resultado econômico de uma empresa está relacionado com a capacidade de prever corretamente, onde o custo de tomar decisões intuitivas, baseadas na sensibilidade que o gestor possui é baixíssimo; contudo o custo incorrido com os erros de previsão supera esta economia. A figura 3.1 apresenta a relação *trade-off* custo/precisão que a empresa deve escolher a região de operação ideal dentre os diferentes métodos de previsão (WANKE e JULIANELLI, 2011).

Fonte: Adaptado (WANKE e JULIANELLI, 2011).

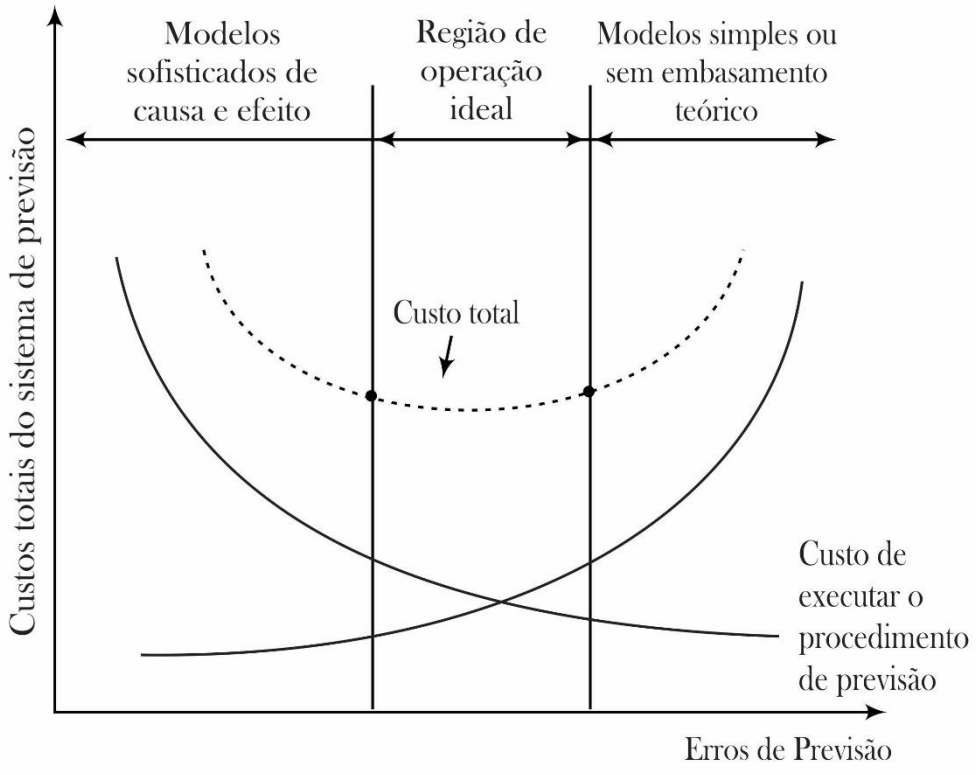

Figura 3.1: Custo da previsão versus custo da imprecisão

3.3 CARACTERÍSTICAS DAS PREVISÕES

Chopra e Meindl (2016) apresentam como características de previsões:

- As previsões são sempre imprecisas, por isso devem incluir o valor esperado e uma medida de erro.
- Quanto maior o horizonte de previsão, maior também será o seu desvio padrão.
- As previsões agregadas são mais precisas.
- Quando mais a montante uma empresa está na cadeia de suprimentos (ou mais distante do consumidor final), maior é a distorção de informação que ela recebe.

Já Moreira (2008) apresenta as seguintes características:

- Em geral os métodos de previsão assumem as mesmas causas que estiveram presentes no passado, logo continuarão presentes no futuro.
- Os métodos não conduzem a resultados perfeitos, e a chance de erro é maior quando aumentamos o horizonte de previsão.

3.4 CARACTERÍSTICAS DA DEMANDA

De acordo com Chopra e Meindl (2016), em qualquer método de previsão observa-se um elemento aleatório, que não pode ser explicado por padrões históricos de demanda, desta forma, qualquer demanda observada pode ser dividida em um componente sistemático e um aleatório.

Demanda observada (O) = componente sistemático (S) + componente aleatório (A)

Chopra e Meindl (2016) explicam o componente sistemático como sendo o valor esperado para a demanda e chama-a de nível, sendo essa a demanda atual não sazonal; tendência, é a taxa de crescimento ou decréscimo na demanda para o próximo período; e

sazonalidade, as flutuações sazonais previsíveis na demanda. Já o componente aleatório, é parte inexplicável da demanda, não pode e não deve ser prevista pela empresa, restando apenas acompanhar o erro de previsão, que é a diferença entre a previsão e a demanda real.

Martins e Laugeni (2005), afirmam que para realizar uma previsão é necessário ter informações a respeito da demanda, haja visto que ela obedece à padrões, onde os mais comuns são:

- média, em que as flutuações da demanda estão em torno de um valor constante;
- tendência linear, em que a demanda cresce ou decresce linearmente;
- tendência não linear em que a demanda cresce ou decresce não linearmente;
- sazonal em que a demanda cresce ou decresce, em certos períodos.

Do ponto de vista gerencial, caberá ao gestor identificar a técnica ou modelo que melhor se adeque a natureza dos dados observados a fim de minimizar o erro de previsão. Manter a crença de que o modelo matemático resolverá todos os problemas em um ambiente de profunda incerteza pode não ser necessariamente o caminho correto, doses de experiência e subjetividade devem fazer parte da "caixa-preta de solução" dos tomadores de decisão. Em suma, o objetivo da previsão é filtrar o componente aleatório (ruído) e estimar o componente sistemático.

3.5 MÉTODOS DE PREVISÃO

Diversas técnicas foram desenvolvidas após várias décadas de estudos. Moreira (2008) classifica os métodos pelo tipo de abordagem usada, ou seja, o tipo de instrumentos e conceitos que formam a base da previsão, para ele os métodos podem ser: qualitativos e quantitativos. O método quantitativo subdivide-se em: métodos causais e séries temporais. Chopra e Meindl (2016) concordam e acrescentam o método de simulação onde a empresa combina métodos de séries temporais e causais para tentar imitar as escolhas do consumidor.

Já Ballou (2001), separa em três grupos: qualitativo, projeção histórica e causal. Cada grupo possui as suas especificidades de acurácia relativa ao horizonte de previsão seja ele de curto, médio ou longo prazo, nível de sofisticação quantitativa e base lógica. A escolha do método ideal não é uma decisão fácil, e estudos indicam que a utilização de mais de um método

com a combinação de resultados, garante melhores resultados (CHOPRA e MEINDL, 2016).

O quadro 3.1 contém os métodos apresentados neste trabalho:

Natureza	**Método**
Qualitativo	Opiniões de executivos Opinião da força de vendas Pesquisa junto a consumidores Método Delphi
Causais	Regressão linear simples Regressão linear múltipla
Projeções históricas	Média móvel Alisamento exponencial simples Alisamento exponencial corrigido pela tendência (modelo de Holt) Alisamento exponencial corrigido por tendência e sazonalidade (modelo de Winter)

Quadro 3.1: Métodos de previsão
Fonte: Elaborado pelo autor, 2017

3.5.1 Métodos Qualitativos

Para Moreira (2008), os métodos qualitativos baseiam-se no julgamento e experiência de mercado de pessoas, para que com seu conhecimento possam emitir opiniões sobre eventos futuros. Não só a previsão da demanda, mas também, lançamentos de novos produtos, rumos da tecnologia, movimentos do comércio internacional podem ser utilizados os métodos qualitativos, devido sua natureza subjetiva.

Mesmo na utilização de técnicas quantitativas, o julgamento e o conhecimento dos analistas, podem exercer papel fundamental no processo de previsão, como por exemplo o expurgo de *outliers*, a seleção do melhor método e dados que serão utilizados na análise (WANKE e JULIANELLI, 2011). O potencial humano não deve ser excluído, visando a

necessidade de equilibrar fatores objetivos e subjetivos ao prever a demanda, pois este pode ter acesso a informações sobre aspectos ambientais a qual a organização está inserida, informações estas que não estariam inseridas nos dados históricos (PINHEIRO, VIANA e CASTRO, 2013).

Ballou (2001) classifica os métodos qualitativos aqueles que utilizam a intuição, julgamento e técnicas comparativas, a fim de formar uma base quantitativa e produzir estimativas para o futuro.

É importante perceber que, embora o decisor possua alta compreensão entre os métodos qualitativos e quantitativos, alguma avaliação subjetiva geralmente será necessária em qualquer tipo de previsão da demanda, pois utiliza sentimentos intuitivos e conhecimento de domínio do que está ocorrendo no mercado (CHASE, 2009). Os autores coadunam que, a ausência de dados históricos, lançamentos de novos produtos e falta de segurança ao prever padrões passados que podem não se manter no futuro, são fatores que dificultam a utilização de modelos quantitativos.

3.5.1.1 Opiniões de Executivos

Trata-se de um grupo, em geral pequeno, de altos executivos da empresa que reúne-se para desenvolver em conjunto uma previsão. São profissionais de diversas áreas, como marketing, finanças, produção, finanças, etc. A vantagem do método está na reunião de talentos com diferentes visões do assunto, o que pode contribuir com precisão e qualidade às decisões do grupo. A desvantagem, é que uma das pessoas, devido sua personalidade forte, exerça influência no grupo, impondo em maior ou menor grau a própria opinião (MOREIRA, 2008).

3.5.1.2 Opinião da Força de Vendas

Estabelecer previsões baseando-se na opinião dos profissionais de vendas pode ser uma alternativa atraente devido a sua proximidade com o produto e o consumidor. Alguns problemas desse método são: o pessoal de vendas pode ser influenciado por eventos de um passado recente, em um cenário de vendas boas podem superestimar a demanda; se ruins, talvez subestime-a. Ainda, se as previsões forem usadas para fixar cotas mínimas de vendas, cria-se um conflito de interesses, onde possivelmente os vendedores podem projetar baixas estimativas da demanda (MOREIRA, 2008). Ballou (2001), acrescenta que as opiniões da força de vendas

são válidas, desde que os profissionais de vendas estejam próximos ao cliente e em boa posição para prever suas necessidades.

3.5.1.3 Pesquisas Junto a Consumidores

Comumente conhecido como pesquisa de mercado, esse método consiste em coletar, por amostragem, a opinião particular do consumidor, trata-se de um bom método pois o consumidor é quem determina a demanda. As pesquisas de mercado requerem conhecimentos técnicos especializados e cuidado no seu planejamento. Montar a estrutura de pesquisa, os instrumentos de coleta dos dados, plano de execução e interpretar os resultados, pode ser oneroso para a empresa, dispendendo recursos financeiros e humanos, contudo pode gerar resultados compensadores (MOREIRA, 2008).

Este tipo de pesquisa visa determinar intenções de compra de determinados produtos e mede sentimento geral do consumidor a respeito do presente e futuro, estimando como esse sentimento afetará hábitos de compras. Uma desvantagem, é que pode ser sinalizado um ponto de inflexão incorretamente (BALLOU, 2001).

3.5.1.4 Método Delphi

O nome Delphi deriva da Grécia Antiga, do oráculo *Delphos*, que oferecia visões do futuro. A técnica caracteriza-se por um processo que estrutura a comunicação grupal, com garantia de anonimato, onde é aplicado um questionário em que todos são instados a emitir opiniões em relação ao tema, esses questionários são reunidos, compilados e analisados estatisticamente, os resultados são apresentados ao grupo e uma nova rodada de questionários são aplicados até que haja uma convergência das respostas (WANKE e JULIANELLI, 2011).

É importante destacar que a respostas daqueles que divergem da mediana do grupo, o participante terá a oportunidade de reavaliar a sua resposta, podendo manter ou não a sua posição, através da troca de *feedback*, até que o consenso atinja um nível satisfatório (MOREIRA, 2008). De acordo com Ballou (2001), essa técnica elimina o efeito de massa da opinião da maioria.

A figura 3.2 apresenta os passos do processo:

Fonte: Adaptado (WANKE e JULIANELLI, 2011).

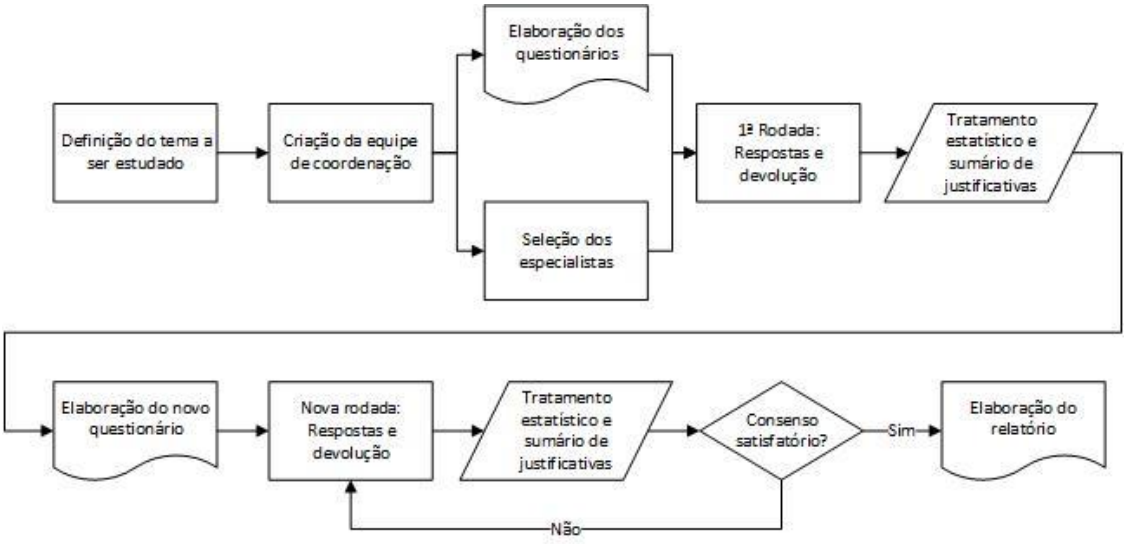

Figura 3.2: Operacionalização da técnica Delphi

Abaixo as vantagens e desvantagens apontados por Wanke e Julianelli (2011):
Vantagens:

- A consolidação de pensamentos independentes e formação gradual de soluções pelo grupo.
- Realiza previsões em situações de carência de dados históricos.
- Minimiza pressões psicológicas existentes em reuniões.
- O uso de questionários requer maior reflexão e cuidados ao respondente
- A distância física não é um empecilho, pois não são necessárias reuniões físicas, dessa forma os custos são menores quando comparados a técnicas que necessitam de reunião física.

Desvantagens:

- Processo relativamente lento.
- A escolha dos especialistas pode influenciar os resultados.
- Dificuldade de redigir questionário não viesado e sem ambiguidades.
- Possibilidade de forçar consenso.

- Apesar de ter custos menores quando comparado a uma reunião, apresenta custos elevados na fase de preparação.

3.5.2 Métodos Causais

Os métodos de previsão causais supõem que exista uma correlação entre demanda e fatores ambientais (o estado da economia, taxas de juros etc.), e esses fatores ambientais serão utilizados para prever a demanda futura (CHOPRA e MEINDL, 2016). O administrador deve investigar a força e a natureza da relação de uma ou mais variáveis exercem na demanda, devendo avaliar qual técnica é a mais adequada (WANKE e JULIANELLI, 2011).

Se a previsão se baseia em único fator, a regressão linear simples é o modelo indicado, para o uso de mais de um fator de previsão é a regressão múltipla (BOWERSOX, CLOSS, *et al.*, 2014). A seguir será abordado essas técnicas.

3.5.2.1 Regressão Linear Simples

Esse modelo contém um único regressor, tendo a linha reta como a representação geométrica da relação entre a resposta y e o preditor x (WANKE e JULIANELLI, 2011). A equação 3.1 representa o modelo:

$$Y = a + bX \tag{3.1}$$

Onde:

- **Y** = variável dependente
- **X** = variável independente
- **a** = intercepto na reta no eixo y
- **b** = inclinação da reta

Uma ferramenta muito utilizada para a avaliação visual das informações é o diagrama de dispersão, ele permite avaliação preliminar da relação entre a variável resposta e variável

regressora e para a obtenção dos coeficientes utiliza-se o método dos mínimos quadrados (WANKE e JULIANELLI, 2011).

3.5.2.2 Regressão Linear Múltipla

Muito semelhante a regressão linear simples, mas acrescentando mais uma variável independente. Nesse caso não se deve utilizar o diagrama de dispersão, contudo o método dos mínimos quadrados continua sendo a forma de obter os coeficientes (WANKE e JULIANELLI, 2011).

3.5.3 Métodos de Projeção Histórica

A premissa básica para praticamente todas as técnicas quantitativas são de que o comportamento da demanda passada venha a ser utilizada como base para prever estimativas, com isso as técnicas trabalham com séries históricas (WANKE e JULIANELLI, 2011). Tendo em mãos uma quantidade razoável de dados históricos, com tendência e variações sazonais de tempo estáveis e bem definidas, projetar dados no futuro pode ser um meio eficaz de prever para o curto prazo (BALLOU, 2001).

Seria ingênuo achar simplesmente que dados do passado, sem a utilização das técnicas adequadas, irão se repetir exatamente no futuro. Se faz necessário que o modelo corrija, suavize distorções dos dados, para prever com maior acurácia (CHASE, 2009). De acordo com Ballou (2001), estes modelos são reativos por natureza, se amoldando às mudanças assim que novos dados se tornam disponíveis, contudo se as mudanças forem rápidas, até que ocorra, o modelo não sinalizará antes da sua ocorrência. Entretanto, segundo o autor, para previsões de curto tempo, esta não parece ser uma séria limitação, a menos que se tratem de mudanças drásticas.

Segue algumas vantagens e desvantagens (CHASE, 2009):

Vantagens:

- Adequada para previsão de grandes quantidades de produtos.
- Funcionam muito bem para produtos com histórico de vendas bastante estável.
- Podem suavizar pequenas flutuações.
- Bons na previsão de períodos curtos (um a três períodos no futuro).

Desvantagens:

- Exigem uma grande quantidade de dados históricos.
- Se ajustam lentamente às mudanças de vendas.
- Não adequados para horizontes de previsão longo.
- Grandes flutuações nos dados atuais podem lançar previsões com erros grandes.

A seguir será abordado alguns métodos de previsão:

3.5.3.1 Média Móvel

Neste método utilizamos a média aritmética dos últimos *n* valores para prever o valor seguinte, descartando-se o valor mais antigo a cada nova observação (WANKE e JULIANELLI, 2011). A média móvel é utilizada quando a demanda não possui tendência ou sazonalidade observada (CHOPRA e MEINDL, 2016). A equação 3.2 representa o método:

$$L_{t+1} = \frac{D_{t+1}+D_t+\cdots+D_{t-N+2}}{N} \quad (3.2)$$

Onde:

- L = previsão do nível para um determinado período *t*
- D = demanda real observada no período *t*
- t = período de tempo atual
- n = número períodos considerados na média móvel

Cabe destacar que na média móvel todos os períodos têm peso idêntico, então quando o número de períodos é reduzido, a inclusão de novos valores, tendem a apresentar maiores impactos e, quando o número de períodos é alto, a inserção de novas observações apresenta menor sensibilidade (WANKE e JULIANELLI, 2011).

3.5.3.2 Alisamento Exponencial Simples (AES)

O método de alisamento simples é apropriado quando a série não possui tendência e sazonalidade observada. Permite ponderar os valores mais recentes, atribuindo-lhes pesos, pressupondo-se que estes são mais importantes na determinação da previsão (WANKE e JULIANELLI, 2011). Ela baseia a previsão na média ponderada dos níveis anteriores de demanda e previsão, desta forma, "a nova previsão é uma função da previsão antiga incrementada por uma fração do diferencial entre a previsão antiga e as demandas reais" (BOWERSOX, CLOSS, *et al.*, 2014). A equação 3.3 representa o método:

$$L_{t+1} = \alpha D_{t+1} + (1 - \alpha) L_t \tag{3.3}$$

Onde:

- **α** = constante de alisamento para o nível ($0 \leq \alpha \leq 1$)

A constante de alisamento varia de 0 a 1, quando o valor estiver mais próximo de 1, os períodos mais recentes irão ter alta influencia na previsão, o efeito prático é a sua resposta rápida às mudanças. Um valor muito baixo, tornará o modelo muito semelhante a uma média simples, e como resultado, reagindo lentamente às mudanças (BOWERSOX, CLOSS, *et al.*, 2014). Aumentar a constante, deixará a previsão mais "nervosa", seguindo as variações aleatórias ao invés de mudanças fundamentais (BALLOU, 2001). O gestor de estoque enfrenta *trade-off* entre eliminar as flutuações aleatórias ou ter uma previsão que reaja completamente a alterações na demanda (BOWERSOX, CLOSS, *et al.*, 2014). Mais adiante, este trabalho abordará a otimização da constante de alisamento através de medidas de previsão de erro e a utilização de *softwares*.

Para a primeira previsão, pode-se utilizar uma média de todos os dados históricos, pois a demanda foi considerada sem tendência ou sazonalidade (CHOPRA e MEINDL, 2016).

3.5.3.3 Alisamento Exponencial Corrigido pela Tendência (Modelo de Holt)

Embora o método AES traga bons resultados, quando há uma significativa tendência ou sazonalidade, trará uma defasagem inerente da estimativa, levando a erros inaceitáveis de previsão (BALLOU, 2001). Para corrigir a tendência, uma segunda constante é adicionada especificamente para esse fim (WANKE e JULIANELLI, 2011). As equações 3.4, 3.5 e 3.6 representam o método:

$$L_{t+1} = \alpha D_{t+1} + (1 - \alpha)(L_t + T_t) \quad (3.4)$$

$$T_{t+1} = \beta(L_{t+1} - L_t) + (1 - \beta)T_t \quad (3.5)$$

$$F_{t+1} = L_t + T_t \quad (3.6)$$

Onde:

- **T** = tendência para o período
- **β** = constante de alisamento para a tendência ($0 \leq \alpha \leq 1$)
- **F** = previsão da demanda para o período *t*

A primeira equação é resultado da adição do termo relativo a estimativa da tendência encontrada no AES. A segunda equação ajusta a estimativa de tendência, ponderando a estimativa anterior e a mais recente com a constante β. Por último, a terceira equação retorna a previsão para *t* períodos à frente. Assim como acontece com a constante α, deve-se otimizar β com o auxílio de *softwares*, sendo que a precisão do método de Holt está diretamente relacionada à seleção dessas constantes (WANKE e JULIANELLI, 2011).

A estimativa inicial de nível e tendência pode ser obtida executando uma regressão linear entre a demanda D_t e o período *t* na forma da equação 3.7. A utilização da regressão linear é adequada porque consideramos que a demanda tem uma tendência, mas não sazonalidade, portanto existe uma relação entre a demanda e o tempo, tornando-a linear. A constante *b* mede a estimativa de demanda no período *t* = 0 e é a estimativa inicial L_0. A inclinação *a* mede a taxa de mudança na demanda por período e é nossa estimativa inicial da tendência T_0 (CHOPRA e MEINDL, 2016).

$$D_t = at + b \tag{3.7}$$

3.5.3.4 Alisamento Exponencial Corrigido por Tendência e Sazonalidade (Modelo de Winter)

Esse método é apropriado quando o componente sistemático da demanda tem uma tendência e um fator sazonal. Ballou (2001) alerta que para a aplicação deste modelo, é necessário verificar se a demanda sazonal é "estável, significativa e discernível das variações aleatórias". Caso essas condições não sejam satisfeitas, a aplicação de modelos mais simples de ponderação exponencial, com um valor elevado da constante, pode resolver o problema da defasagem da estimativa, produzindo uma previsão mais acurada.

Para estimar o nível no período 0 e a tendência utiliza-se a regressão linear, mas antes é necessário dessazonalizar a demanda. A demanda dessazonalizada representa a demanda que teria sido observada na ausência de flutuações sazonais. A equação 3.8 a seguir demonstra como fazer (CHOPRA e MEINDL, 2016).

$$\overline{D}_t = \begin{Bmatrix} \left[D_{t-(p/2)} + D_{t+(p/2)} + \sum_{i=t+1-(p/2)}^{t-1+(p/2)} 2D_i\right]/2p \text{ para } p \text{ par} \\ \sum_{i=t-[(p-1)/2]}^{t+[(P-1)/2]} D_i/p \text{ para } p \text{ ímpar} \end{Bmatrix} \tag{3.8}$$

Onde:

- $\overline{\boldsymbol{D}}_{\boldsymbol{t}}$= demanda dessazonalizada
- $\boldsymbol{D_t}$ = demanda observada
- $\boldsymbol{p}$ = número de períodos em que o ciclo sazonal se repete

Com a demanda dessazonalizada, estabelece-se a relação linear entre a demanda e o tempo conforme a equação 3.9.

$$\overline{D}_t = L + Tt \tag{3.9}$$

A seguir estima-se os valores de *L* e *T* com a regressão linear da demanda dessazonalizada. É importante deixar claro que não é apropriado realizar a regressão linear entre os dados de demanda originais e o tempo para estimar o nível e a tendência, pois os mesmos não são lineares (CHOPRA e MEINDL, 2016). Para estimar os fatores sazonais, determina-se a razão entre a demanda real D_t e a demanda dessazonalizada $\bar{D}_t$, obtendo o fator sazonal $\bar{S}_t$ para o período *t* e é dada pela equação 3.10.

$$\bar{S}_t = \frac{D_t}{\bar{D}_t} \tag{3.10}$$

Observando a demanda para o período *t* + 1, obtém as estimativas de nível, tendência e fatores sazonais com as equações 3.11 a 3.14.

$$L_{t+1} = \alpha\left(\frac{D_{t+1}}{S_{t+1}}\right) + (1-\alpha)(L_t + T_t) \tag{3.11}$$

$$T_{t+1} = \beta(L_{t+1} - L_t) + (1-\beta)T_t \tag{3.12}$$

$$S_{t+p+1} = \gamma\left(\frac{D_{t+1}}{L_{t+1}}\right) + (1-\gamma)S_{t+1} \tag{3.13}$$

$$F_{t+1} = (L_t + T_t)S_{t+1} \tag{3.14}$$

Onde:

- **S** = sazonalidade para o período
- γ = constante de alisamento para a sazonalidade ($0 \leq \gamma \leq 1$)

Usamos a equação 3.13 para calcular o ajuste sazonal da série, e somente ao calcular a previsão para o período *t* + 1voltamos a incorporar o componente sazonal (equação 3.14). Idem ao modelo de Holt, a otimização das constantes (α, β e γ) é fundamental para que o modelo produza previsões satisfatórias (WANKE e JULIANELLI, 2011).

3.6 ERROS DE PREVISÃO

Conforme já citado neste trabalho, Chase (2009) afirma que seria ingênuo achar que o passado se repetirá puro e simplesmente no futuro sem a utilização das técnicas adequadas. Ballou (2001), afirma que o futuro não é espelhado perfeitamente no passado, por isso a previsão conterá erros em algum nível. Erro de previsão mostrará o quão próximo a mesma está da demanda real. Moreira (2008) e Wanke e Julianelli (2011), concordam que os erros de previsão são importantes para avaliar qual o método mais adequado para a série de dados, bem como acompanhar o desempenho de um modelo já escolhido.

Para Chopra e Meindl (2016), um bom método de previsão deve ser capaz de capturar o componente sistemático de demanda, mas não o componente aleatório. É o componente aleatório que chama-se de erro de previsão. Os gestores devem se conscientizar da importância dessa informação, porque é através dela que ele irá determinar se o método de previsão atual está prevendo o componente sistemático adequadamente e traçar planos de contingência. A equação 3.15 define o erro de previsão para o período *t*:

$$E_t = F_t - D_t \tag{3.15}$$

A seguir será apresentado os métodos de erro de previsão mais utilizados.

3.6.1 Mean Absolute Deviation (MAD)

O MAD avalia o nível de erro a partir do cálculo do erro absoluto médio, tendo como um ponto positivo deste método é o fato de um valor negativo não anular um positivo, devido as diferenças serem tomadas em valor absoluto. A equação 3.16 descreve o MAD:

$$MAD = \frac{\sum_{t=1}^{n} |E_t|}{n} \tag{3.16}$$

3.6.2 Mean Absolute Percentual Error (MAPE)

O MAPE avalia a magnitude do erro em relação à demanda, calculam-se o erro

absoluto médio como uma porcentagem da demanda. É expresso na equação 3.17 (CHOPRA e MEINDL, 2016).

$$MAPE_n = \frac{\sum_{t=1}^{n}\left|\frac{E_t}{D_t}\right|100}{n} \tag{3.17}$$

3.6.3 Mean Squared Error (MSE)

O MSE calcula a média dos erros ao quadrado, neste método os *outliers* (valores que apresentam grande discrepância em relação à série de dados) recebem maior peso, e o contrário ocorre com erros menores. Chopra (2016) expressa o MSE conforme a equação 3.18.

$$MSE_n = \frac{1}{n}\sum_{t=1}^{n} E_t^2 \tag{3.18}$$

Uma característica desse cálculo é que sua unidade não é a mesma dos dados da demanda, contudo pode ser contornado utilizando-se a raiz quadrada do MSE (WANKE e JULIANELLI, 2011).

3.6.4 Mean Percentual Error (MPE)

O objetivo do MPE é medir se o método possui algum viés, ou seja, se o método sistematicamente superestima ou subestima a demanda. Para previsões não viesadas, espera-se um valor de MPE próximo de zero. A equação 3.19 a seguir, expressa o MPE (CHOPRA e MEINDL, 2016).

$$MPE_n = \sum_{t=1}^{n} E_t \tag{3.19}$$

3.6.5 Sinal de Acompanhamento (SA)

O SA é a razão entre o MPE e o MAD, sendo calculado como na equação 3.20:

$$SA_t = \frac{MPE_n}{MAD_n} \tag{3.20}$$

Se o SA em qualquer período estiver fora do intervalo ±6, indica que a previsão é viesada e está prevendo a menos (SA ≤ -6) ou a mais (SA ≥ +6). Nesse caso, o gestor pode decidir escolher um outro método (CHOPRA e MEINDL, 2016). O SA mede o quanto a previsão se distancia da demanda, podendo dessa forma ser utilizado como uma excelente forma de medir o poder preditivo de um modelo.

3.7 OTIMIZAÇÃO DAS CONSTANTES DE ALISAMENTO

Como mencionado anteriormente, o grau de precisão que pode-se obter com os modelos que utilizam métodos de amortecimento está diretamente ligado aos valores escolhidos para os seus coeficientes (WANKE e JULIANELLI, 2011).

Uma abordagem que pode ser utilizada é minimizar o erro de previsão que o gestor se sinta mais confortável como o MAD, MAPE, MSE ou MPE. Na ausência de uma preferência entre os termos, é melhor escolher o MSE. (CHOPRA e MEINDL, 2016).

Um algoritmo que pode ser utilizado para minimizar o erro de previsão é a ferramenta Solver®, presente no Excel® do pacote MS-Office. Em conjunto com a planilha eletrônica, é possível aplicar os modelos apresentados nesse trabalho otimizando as suas constantes. Contudo, torna-se importante destacar que o algoritmo utilizado por esta ferramenta pode retornar ótimos locais e não globais, assim não garantindo que o resultado encontrado seja realmente o ótimo (WANKE e JULIANELLI, 2011).

Uma heurística que pode ser utilizada é a SAFT (*Self-Adaptive Forecasting Techinique*), desenvolvida por Robert e Reeds (1969, apud WANKE e JULIANELLI, 2011). Esta técnica pode ser aplicada em qualquer método de amortecimento; entretanto, como exemplo ela será descrita considerando a determinação dos três coeficientes de Winter. A técnica consiste em duas etapas: na primeira, avaliam-se todas as combinações possíveis entre os valores possíveis para cada coeficiente:

$$\alpha \in \{0{,}05;\ 0.10;\ 0{,}15;\ 0{,}20;\ldots;\ 0{,}90;\ 0{,}95\}$$
$$\beta \in \{0{,}05;\ 0.10;\ 0{,}15;\ 0{,}20;\ldots;\ 0{,}90;\ 0{,}95\}$$
$$\gamma \in \{0{,}05;\ 0.10;\ 0{,}15;\ 0{,}20;\ldots;\ 0{,}90;\ 0{,}95\}$$

Após avaliar as 6.859 (19 x 19 x 19) combinações seleciona-se aquela que resultou o menor erro médio. Com os valores definidos de α, β e γ, dá-se início a segunda etapa, com o objetivo de encontrar o local por um valor ainda menor de erro, testando outros valores quatro níveis abaixo e quatro níveis acima de cada coeficiente em incrementos de 0,01. Como resultado obtêm-se 512 (8 x 8 x 8) combinações adicionais para testar e selecionar a que apresenta o menor erro médio. No total a heurística testa 7.371 (6.859 + 512) combinações.

CAPÍTULO 4 - METODOLOGIA

4.1 INTRODUÇÃO

Este capítulo apresenta os procedimentos metodológicos utilizados na realização deste trabalho.

4.2 PROCEDIMENTOS METODOLÓGICOS

Para classificação da pesquisa, torna-se como base a sistemática apresentada por Vergara (1998), que a qualifica em relação a dois aspectos: quanto aos fins e quanto aos meios.

Quanto aos fins, trata-se de uma pesquisa aplicada, motivando-se pela necessidade de resolver problemas concretos, sendo assim de finalidade prática, buscando aplicar modelos matemáticos que auxiliem o gestor no processo decisório de previsão da demanda (VERGARA, 1998).

Quantos aos meios, trata-se de uma pesquisa bibliográfica e *ex post facto*. Bibliográfica porque foi realizado uma revisão acerca do tema previsão da demanda, justificando a sua importância no contexto da gestão de estoques, listando técnicas e métricas, bem como as limitações e aplicações de cada uma delas. Ainda na revisão foram utilizados livros clássicos sobre o tema, aliado a leituras complementares de artigos nacionais e internacionais (VERGARA, 1998).

A investigação *ex post facto* se caracteriza por um fato já ocorrido, onde o pesquisador não pode controlar as variáveis porque elas já ocorreram. Como este trabalho foi realizado com dados históricos, justifica-se essa classificação (GIL, 1989).

Este trabalho possui a natureza de um estudo aplicado haja vista que as técnicas mencionadas no referencial teórico, foram devidamente implementadas numa empresa real no segmento da indústria têxtil. É também classificada como quantitativa, devido à característica de análise de dados (GIL, 1989).

Com relação aos dados, os mesmos foram auferidos pelo departamento de TI da empresa, consolidados via SQL (*Structured Query Language*), entregue ao autor para que fossem preparados para a análise. Com os dados em mãos, foram aplicados os métodos já descritos no referencial teórico deste trabalho, o AES, o modelo de Holt e o modelo de Winter.

Em seguida foi realizado uma análise comparativa com os resultados e erros obtidos, para somente então propor o melhor modelo dentre os observados que explica de maneira mais eficaz a demanda e apresenta as estimativas de previsão com maior acuracidade. Para isso foram utilizados principalmente o suplemento Solver do Excel e Action Stat.

CAPÍTULO 5 - ANÁLISE DOS DADOS E DISCUSSÃO DOS RESULTADOS

5.1 INTRODUÇÃO

Este capítulo apresenta a análise de dados e discussão dos resultados obtidos, através da aplicação dos métodos descritos no referencial teórico.

5.2 INICIATIVA

A gestão de estoque é motivo de constantes reuniões entre a gerência de produção e o departamento almoxarifado, a fim de discutir e consolidar a previsão da demanda. Também é motivo de preocupação da direção da empresa, por esse setor alocar parte substancial do capital financeiro.

A empresa adota o sistema de produção puxada, onde toda a sua produção é exclusivamente sob encomenda, em virtude de se tratar de produto personalizado com a marca de seus clientes. Essa característica de sistema produtivo, produção sob encomenda, apresenta-se como grande desafio para a empresa em estudo, em decorrência de características idiossincráticas existentes na relação com fornecedores de insumos para a produção, tais como descasamento entre oferta e demanda, oscilações de taxa de câmbio, etc., mas o principal problema com o qual a empresa se defronta é que o seu *lead time* de ressuprimento é elevado, chegando a ser três vezes maior que o seu prazo de entrega dos pedidos a seus clientes.

A preocupação por parte da direção é o crescimento rápido e contínuo do estoque bem como as ocorrências de ruptura do mesmo. Estes fatos encarecem a operação e deixa a empresa menos competitiva no seu setor, dado a precariedade nas relações com clientes potenciais, que na maioria das vezes são responsáveis por maiores margens de lucro para a empresa. Uma outra preocupação é como tratar a sazonalidade, no momento é feita manualmente pela equipe de gestão de estoque sem nenhuma análise mais precisa da natureza da demanda.

5.3 DEFINIÇÃO DO PROBLEMA

O problema a ser resolvido é definir um modelo de previsão de demanda que estime o volume de produto a ser comprado, levando-se em questão a peculiaridade dos dados. O método que a empresa utiliza atualmente é um método de projeção histórica simples, a maior média móvel dos últimos 3, 6 ou 12 meses. Por isso o principal objetivo desse estudo é encontrar novas soluções que resultem em melhores estimativas para a demanda e contribua para aperfeiçoar a gestão logística da cadeia de suprimentos a qual a empresa está inserida, através da análise comparativa das técnicas de séries temporais.

5.4 PREPARAÇÃO DOS DADOS

A série de dados que foi fornecida para este trabalho, totalizaram 72 meses. Para efeito de comparação, foi simulado a técnica atual adotada pela empresa e as técnicas descritas no referencial teórico, a saber, AES, modelo de Holt e modelo de Winter.

5.5 SOFTWARE

O programa computacional utilizado para rodar os modelos foi o Excel®, junto com o seu suplemento de otimização o Solver® e também o Action Stat.

5.6 MODELO MATEMÁTICO

Os modelos matemáticos testados para avaliação de desempenho, em comparação com o modelo atual foram:

- Média móvel (pico da maior média móvel entre 3, 6 e 12 meses)
- Alisamento exponencial simples
- Alisamento exponencial corrigido pela tendência (modelo de Holt)
- Alisamento exponencial corrigido pela tendência e sazonalidade (modelo de Winter)

Cada um dos métodos foi colocado em uma aba do programa.

5.6.1 Média móvel

Para o método de média móvel foi utilizado a maior média entre 3, 6 e 12 meses (modelo atual da empresa). Foi utilizado a função “MÉDIA” no Excel, de cada um dos modelos e escolhendo o maior entre eles. A tabela 5.1 ilustra uma amostra da organização da planilha para a média móvel.

Tabela 5.1: Modelagem da média móvel

Período	Demanda	MM3	MM6	MM12	Previsão
13	1.532	1.169	1.281	1.331	1.331
14	1.087	1.213	1.340	1.313	1.340
15	1.183	1.174	1.281	1.328	1.328
16	1.121	1.267	1.218	1.309	1.309
17	1.291	1.130	1.172	1.275	1.275
18	1.212	1.198	1.186	1.275	1.275
19	1.160	1.208	1.238	1.259	1.259
20	1.671	1.221	1.176	1.258	1.258

Fonte: Empresa estudada, 2017

Note que a modelagem começa no período 13, isso ocorre porque os últimos 12 meses foram utilizados para compor o cálculo da MM12.

5.6.2 Alisamento Exponencial Simples (AES)

Para esse modelo, não basta apenas os dados históricos, mas também a constante de alisamento α para o nível, com valores entre zero e um, como foi explicado no referencial teórico. Para a previsão inicial foi utilizada uma média simples de toda a série histórica, posteriormente para os demais períodos a técnica AES foi utilizada.

5.6.3 Alisamento Exponencial Corrigido pela Tendência (Modelo de Holt)

Muito parecido com o AES, o modelo de Holt também possui constantes de alisamento, só que neste caso são duas, uma para nível (α) e outra para tendência (β). Para a previsão inicial foi feita uma regressão linear e para os demais períodos foi utilizado o modelo

de Holt. Todas as fórmulas estão descritas no referencial teórico e foram adaptadas ao Excel®.

5.6.4 Alisamento Exponencial Corrigido por Tendência e Sazonalidade (Modelo Winter)

Similar ao modelo de Holt, mas com o acréscimo de uma terceira constante de alisamento γ relacionada a sazonalidade. Para a obtenção da previsão inicial, os dados foram dessazonalizados e realizado uma regressão linear com os dados sem o fator sazonal. Para os próximos períodos foi utilizado o modelo de Winter, que já foi detalhado no capítulo 3.

5.7 MEDIÇÃO DE ERRO

Com os cálculos prontos, para todos os modelos, chegou o momento de analisar o poder preditivo de cada modelo medindo o seu erro, para que dessa forma seja feita uma comparação. Foram utilizados os erros MAD, MAPE e MSE. A escolha da melhor medição de erro foi dada por aquela que ofereceu o melhor SA ficando no intervalo de ±6. O SA é a razão entre o MPE e o MAD, e ele mede o quanto viesada está a previsão. Todos os erros de medição já explicados no referencial teórico.

5.8 OTIMIZAÇÃO DAS CONSTANTES DE ALISAMENTO

Os modelos de alisamento exponencial possuem constantes que variam entre zero e um, e sua manipulação pode alterar significativamente as previsões, melhorando-a ou piorando-a. Com o auxílio do suplemento Solver® do Excel® foi realizada a otimização dessas variáveis de forma a minimizar os erros MAD, MAPE e MSE. Cada um desses erros de medição são descritos no tópico anterior.

Na parametrização do Solver o campo “Definir Objetivo” é preenchido com a célula que contém a medição do erro, pois o objetivo é minimizá-lo, foi selecionado a opção “Mín.”, selecionado as células no campo “Alterando Células Variáveis” que continham as variáveis de alisamento a qual deveriam ser testadas pelo Solver para minimizar o objetivo, ainda no campo “Sujeito às Restrições”, através do botão “Adicionar”, foi incluído as restrições contidas na

literatura para cada variável, o Solver deveria buscar um número entre zero e um, testando a melhor combinação para minimizar o erro. A figura 5.1 demonstra os parâmetros do Solver no Excel.

Fonte: O autor

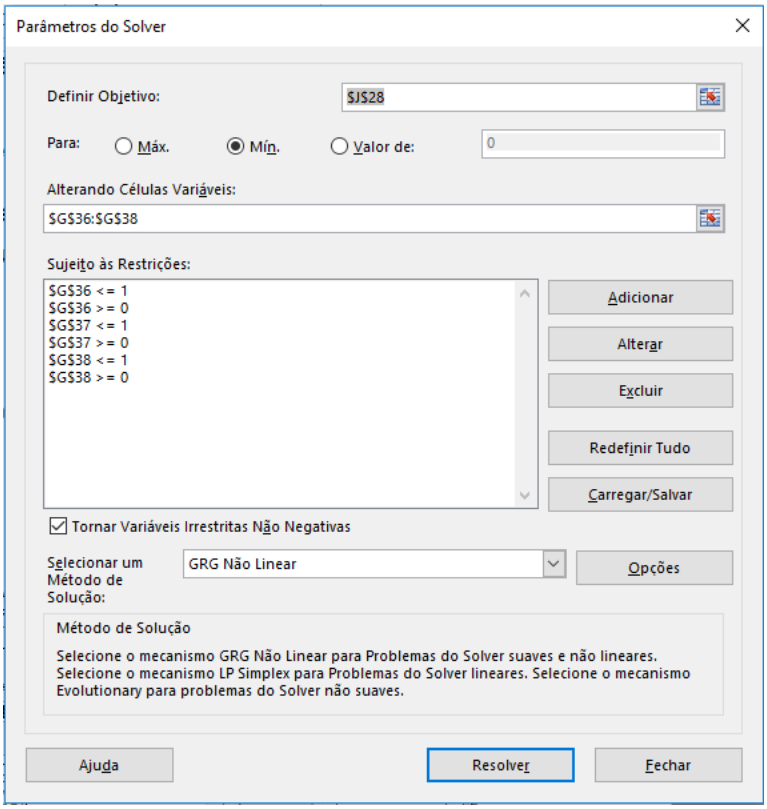

Figura 5.1: Parâmetros no Solver utilizados para a otimização

Essa é a função objetiva, minimizar, por sua vez, cada uma das medidas de erro, alterando as células das constantes, que são as variáveis de alisamento, delimitando-as entre zero e um, a qual forma as restrições.

5.9 CONSOLIDAÇÃO DOS RESULTADOS

Já modelados e otimizados, os resultados são comparados entre si.

5.9.1 Otimização MAD

A primeira otimização foi feita com erro MAD, que permite avaliar o nível de erro da previsão de demanda a partir do erro absoluto médio, o Solver nos forneceu as seguintes constantes de alisamento para cada modelo:

- AES: $\alpha = 0{,}82$
- Holt: $\alpha = 0{,}49$ e $\beta = 0$
- Winter: $\alpha = 0$; $\beta = 0{,}01$ e $\gamma = 0$

É conveniente recordar, como descrito no referencial teórico, um SA negativo significa que o modelo está prevendo a menos e SA positivo significa que o modelo está prevendo a mais. Conforme entendimento da empresa "é melhor pecar pelo excesso do que pela falta" (GERÊNCIA, 2017), foi dado maior ênfase para os modelos que tenham os menores valores negativos (absoluto), mas sem deixar de analisar o SA positivo para que este não traga aumento de estoque. Partindo dessa premissa, para otimização pelo erro MAD, o melhor modelo foi o de Holt, como pode ser observado na tabela 5.2. As memórias de cálculos estão no apêndice A.

Tabela 5.2: Otimização MAD

Método de previsão	**MAD**	**MAPE (%)**	**Intervalo de SA**
Média móvel (modelo da empresa)	173	17	-9 a 28,9
Alisamento exponencial simples	394	11	-3,66 a 4,63
Modelo de Holt	372	10	-3,02 a 5,13
Modelo de Winter	392	11	-3,59 a 6,11

Fonte: O autor

5.9.2 Otimização MAPE

Na otimização pelo erro MAPE, cujo o objetivo é de avaliar a magnitude do erro com relação à série histórica, desta vez o Solver nos apontou as seguintes constantes:

- AES: $\alpha = 0,82$
- Holt: $\alpha = 0$ e $\beta = 0$
- Winter: $\alpha = 0,90$; $\beta = 0$ e $\gamma = 0$

Desta feita, o modelo de Winter apresentou o melhor intervalo de SA, variando entre -2,35 e 3,36. A tabela 5.3 apresenta os resultados da otimização pelo erro MAPE.

Tabela 5.3: Otimização MAPE

Método de previsão	**MAD**	**MAPE (%)**	**Intervalo de AS**
Média móvel (modelo da empresa)	173	17	-9 a 28,9
Alisamento exponencial simples	394	11	-3,66 a 4,63
Modelo de Holt	402	11	-4,98 a 6
Modelo de Winter	311	8	-2,35 a 3,36

Fonte: O autor

Percebe-se que além da diminuição da possibilidade da ruptura do estoque, com o menor valor absoluto negativo, houve uma diminuição do nível de estocagem, o que traz uma diminuição dos valores do estoque e do custo associado à manutenção do mesmo. As memórias de cálculos estão no apêndice B.

5.9.3 Otimização MSE

A medida de erro MSE consiste em calcular a média dos erros ao quadrado, novamente utilizando o Solver, as seguintes constantes de suavização foram encontradas:

- AES: $\alpha = 0,70$
- Holt: $\alpha = 0,66$ e $\beta = 0$
- Winter: $\alpha = 0$; $\beta = 0,01$ e $\gamma = 0$

Nessa nova abordagem o modelo de Holt apresentou um desempenho ligeiramente melhor que o de Winter na otimização pelo MAPE, embora o modelo sugira que o estoque tem uma pequena elevação, novamente comparando com Winter com otimização do MAPE. A tabela 5.4 apresenta os resultados. As memórias de cálculos estão no apêndice C.

Tabela 5.4: Otimização MSE

Método de previsão	**MAD**	**MAPE (%)**	**Intervalo de SA**
Média móvel (modelo da empresa)	173	17	-9 a 28,9
Alisamento exponencial simples	401	11	-3,84 a 5
Modelo de Holt	380	10	-2,78 a 3,73
Modelo de Winter	392	11	-3,59 a 6,11

Fonte: O autor

5.10 SOFTWARES DE PREVISÃO

O pacote computacional Excel mostra-se bastante eficaz para pequenas e até médias empresas que tenham poucos itens para prever demanda, para as situações onde se possui um mix muito grande de produtos, faz-se necessário o uso de softwares estatísticos para auxiliar o gestor (CHOPRA e MEINDL, 2016). Para isso existe o SPSS, MATLAB, Minitab, Action Stat que é baseado no R, Forecast Pro, entre outros.

O uso de pacotes estatísticos ou alguma heurística de otimização podem prever com maior grau de eficiência, pois o Solver do Excel procura uma solução ótima, mas não necessariamente a melhor, o uso de ferramentas específicas pode trazer ainda melhores resultados de previsão (WANKE e JULIANELLI, 2011).

Para auxiliar no processo de análise dos dados foi utilizado uma versão *trial* com validade de trinta dias do software Action Stat, o software oferece uma escolha automática de modelo, onde a heurística do programa se encarrega de analisar os dados e indicar o melhor modelo de previsão. Também é possível configurá-lo para testar diversos cenários (EQUIPE STATCAMP, 2014). Rodando o software com os dados foi possível utilizá-lo para encontrar constantes de alisamentos melhores que o Solver do Excel. O programa apontou as seguintes variáveis:

- AES: $\alpha = 0,69$
- Holt: $\alpha = 0,66$ e $\beta = 0,001$
- Winter: $\alpha = 0,885$; $\beta = 0,048$ e $\gamma = 1$

A tabela 5.5 demonstra o intervalo de SA com as constantes calculadas pelo Action Stat.

Tabela 5.5: Otimização com Action Stat

Método de previsão	**MAD**	**MAPE (%)**	**Intervalo de SA**
Média móvel (modelo da empresa)	173	17	-9 a 28,9
Alisamento exponencial simples	401	11	-3,85 a 5,03
Modelo de Holt	380	10	-2,78 a 3,74
Modelo de Winter	337	9	-2,55 a 3,3

Fonte: O autor

Com a configuração mais básica, o software trouxe bons resultados, um estudo aprofundado poderia ser feito para melhorar ainda mais a acuracidade do modelo de previsão utilizando o Action Stat. A saída dos resultados do Action Stat estão no apêndice D.

CAPÍTULO 6 - CONCLUSÕES

6.1 INTRODUÇÃO

Este capítulo apresenta as conclusões deste trabalho, contemplando também, o que foi proposto pelo objetivo geral, bem como pelos objetivos específicos, implicações acadêmicas, as limitações e sugestões para pesquisas futuras

6.2 CONCLUSÕES

Este trabalho chega a resultados interessantes a partir de técnicas relativamente simples, de fácil aplicação e amplamente disponíveis, o que o torna relevante em um contexto de turbulência econômica, onde a ordem do dia é redução de custos e restrição de investimentos, saber o que produzir e quando produzir, ou quanto comprar e quando comprar, representa diferenciais competitivos, e quem detém o uso dessas tecnologias e as domina, sai na frente da concorrência, traz para o negócio a tão almejada eficácia e eficiência.

No tocante ao desenvolvimento deste trabalho, a partir do que a literatura já aponta em termos de modelagem e técnicas de previsão, foi realizado uma revisão bibliográfica acerca das características da demanda e previsão, além de sua importância em um contexto empresarial de rápidas mudanças que exigem decisões certas. Nesse contexto, justifica-se o uso de métodos de previsão tanto qualitativos, como causais e/ou de projeção histórica que melhor estime medidas de erros nos dados reais. O estudo aplicado a esse caso em particular, utilizou-se de dados reais de uma empresa, chegando a um modelo de previsão da demanda ideal, o que se conclui que o objetivo proposto pelo trabalho foi alcançado com certa medida de eficiência.

A análise dos dados nos leva a concluir que os métodos de alisamento exponencial apresentam bom desempenho e erros significativamente menores do que o método adotado pela empresa que é a média móvel, fato que implica em reduções de rupturas de estoque da ordem de 73% e de 88% de compras acima do nível necessário.

O método de Winter, que constitui-se como um dos métodos mais utilizados em diversas situações de previsão, talvez não tenha apresentado com maior intensidade o componente sazonal devido à redução substantiva de faturamento que a empresa sofreu no auge da crise econômica e que ainda afeta de certa forma o país como um todo com implicações para

diversos setores econômicos, dentre os quais o setor têxtil. Tal fenômeno pode ter distorcido a sazonalidade, pois como a empresa está inserida no mundo da moda, esperava-se que os dados analisados no que concerne ao comportamento da demanda passasse por períodos sazonais, algo inerente a este tipo de indústria. Ainda assim, o modelo Winter foi o que apresentou os melhores resultados no estudo.

Os objetivos específicos também foram cumpridos, na medida que o referencial teórico contém um bom resumo acerca dos modelos de previsão abordados durante a pesquisa. Levantamento de dados para aplicação dos modelos bem como a otimização deles pelas principais medidas de erro otimização das constantes de alisamento. Os dados expostos nas tabelas 5.1 a 5.5, mostraram-se interessantes e embasados na literatura, podendo trazer ganhos significativos caso sejam implementados.

6.3 IMPLICAÇÕES GERENCIAIS

As principais implicações acadêmicas desta pesquisa são:

- Contribuição para que o gestor planeje de forma mais acurada a previsão da demanda e melhore o desempenho da operação;
- Contribuição para que o administrador tenha em mãos várias ferramentas a seu dispor e aplica-las no ambiente mais favorável para cada especificidade dos itens de estoque;
- Contribuir para que as rupturas de estoque sejam minimizadas;
- Contribuir com uma possível redução de estoque e redução do custo de mantê-lo uma vez que este constitui uma fração importante dos custos logísticos.
- Motivar novos estudos em previsão de demanda a partir de comparações entre métodos quantitativos e heurísticas de otimização.

6.4 LIMITAÇÕES

O tempo foi o principal obstáculo para não avançar mais no desenvolvimento deste trabalho. A ideia seria utilizar outras heurísticas de otimização para determinar os pesos das constantes de suavização e compará-los com os resultados encontrados pelas técnicas mais

usuais.

Por outro lado, a ferramenta Solver do Microsoft Excel embora seja limitado quando comparado com softwares estatísticos mais avançados, mostrou-se robusto e trouxe boas respostas nas interações, o que o torna uma ferramenta interessante e de baixo custo.

6.5 SUGESTÕES DE TRABALHOS FUTUROS

Estender e consolidar as técnicas aqui apresentadas para demais itens de estoque, apoiado se possível, pelo uso de software estatístico. Aprofundar os estudos com outros modelos preditivos como o ARIMA, SARIMA e algumas técnicas de inteligência artificial como redes neurais e lógica Fuzzy.

REFERÊNCIAS

BALLOU, H. R. **Gerenciamento da cadeia de suprimentos**. 4ª edição. ed. São Paulo: Bookman Companhia Editora, 2001.

BNDES. Quem pode ser cliente. **BNDES - O banco nacional do desenvolvimento**, 2017. Disponivel em: <https://www.bndes.gov.br/wps/portal/site/home/financiamento/guia/quem-pode-ser-cliente/>. Acesso em: 06 dez. 2017.

BOWERSOX, D. J. et al. **Gestão logística da cadeia de suprimentos**. Porto Alegre: AMGH Editora Ltda., 2014.

CHASE, C. W. J. **Demand-Driven Forecasting:** a structured approach to forecasting. Hoboken: Jonh Wiley & Sons, Inc., 2009.

CHOPRA, S.; MEINDL, P. **Gestão da cadeia de suprimentos:** estratégia, planejamento e operações. São Paulo: Pearson Education do Brasil Ltda., 2016.

EQUIPE STATCAMP. Software Action. **Estatcamp- Consultoria em estatística e qualidade**, 2014. Disponivel em: <http://www.portalaction.com.br>. Acesso em: 17 nov. 2017.

GIL, A. C. **Métodos e técnicas de pesquisa social**. 2ª. ed. São Paulo: Editora Atlas, 1989.

GLOBO, O. Indústria brasileira resiste a reconhecer a China como economia de mercado. **O Globo**, 2017. Disponivel em: <https://oglobo.globo.com/economia/industria-brasileira-resiste-reconhecer-china-como-economia-de-mercado-20744341>. Acesso em: 17 dez. 2017.

JIANG, P.; LIU, X.; YUAN, Y. An adaptative data-driven model for erratic demand forecasting. **IFAC-PapersOnLine**, v. 50, n. 1, p. 9020-9025, Julho 2017. ISSN 2405-8963.

MARTIN, A. C. et al. Análise de séries temporais para previsão da evolução do número de automóveis no município de Joinville. **Espacios**, Caracas, v. 37, n. 6, p. 29, 2016. ISSN 0798-1015.

MARTINS, P. G.; LAUGENI, F. P. **Administração da produção**. 2ª. ed. São Paulo: Editora Saraiva, 2005.

MEDEIROS, R. Á. O. D. et al. Previsão de demanda a médio prazo aplicada em dados reais do sistema de distribuição: uma comparação entre RNA e Lógica Fuzzy. **Principia**, João Pessoa, n. 31, p. 77-86, Dezembro 2016. ISSN 1517-0306.

MORAIS, R. R. D.; SOUSA, N. A.; MORAIS, A. R. D. **Comparativo entre modelos**

de série temporal para previsão de demanda de um item com comportamento intermitente de demanda. XVIII SIMPÓSIO DE ADMINISTRAÇÃO DA PRODUÇÃO, LOGÍSTICA E OPERAÇÕES INTERNACIONAIS. São Paulo: [s.n.]. 2015.

MOREIRA, D. A. **Administração da produção e operações**. São Paulo: Cengage Learning Edições Ltda., 2008.

PINHEIRO, A. R.; VIANA, F. L. E.; CASTRO, E. A. L. **Aplicação de técnicas de previsão de demanda na indústria de confecções**. XXXIII ENCONTRO NACIONAL DE ENGENHARIA DE PRODUÇÃO. Salvador: [s.n.]. 2013.

QUEIROZ, F. C. B. P. et al. Previsão e séries temporais para tomada de decisão empresarial em uma indústria moveleira da região de Criciúma-SC. **Revista Catarinense da Ciência Contábil**, Florianópolis, v. 11, n. 32, p. 26-42, abr./jul. 2012. ISSN 1808-3781.

ROMUALDO, L. C. D. S.; BAPTISTA, E.; VIEIRA, D. R. Sistema Fuzzy-Expert para previsão de séries temporais no supply chain. **Mundo Logística**, Maringá, n. 15, p. 74-82, mar./abr. 2010. ISSN 1982-1832.

VERGARA, S. C. **Projetos e relatórios de pesquisa em administração**. 2ª. ed. São Paulo: Editora Atlas, 1998.

WANKE, P.; JULIANELLI, L. **Previsão de vendas**. São Paulo: Editora Atlas, 2011.

APÊNDICE A – Otimização MAD

Otimização do modelo AES

Período t	Demanda D_t	Nível L_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
0		3.816								
1	4.060	4.016	3.816	- 243	243	59.250	243	6	6	- 1,00
2	4.223	4.185	4.016	- 207	207	50.973	225	5	5	- 2,00
3	4.177	4.179	4.185	8	8	34.004	153	0	4	- 2,89
4	3.507	3.628	4.179	671	671	138.125	282	19	8	0,81
5	3.802	3.771	3.628	- 174	174	116.549	261	5	7	0,21
6	3.623	3.650	3.771	148	148	100.752	242	4	6	0,84
7	4.757	4.558	3.650	- 1.107	1.107	261.500	365	23	9	- 2,47
8	5.050	4.961	4.558	- 492	492	259.089	381	10	9	- 3,66
9	4.141	4.289	4.961	820	820	305.081	430	20	10	- 1,34
10	4.282	4.283	4.289	6	6	274.577	388	0	9	- 1,47
11	4.652	4.586	4.283	- 369	369	261.982	386	8	9	- 2,43
12	4.056	4.151	4.586	530	530	263.560	398	13	9	- 1,03
13	3.892	3.939	4.151	259	259	248.463	387	7	9	- 0,38
14	3.773	3.803	3.939	165	165	232.670	371	4	9	0,04
15	4.205	4.132	3.803	- 402	402	227.920	373	10	9	- 1,03
16	3.933	3.969	4.132	200	200	216.163	363	5	9	- 0,51
17	3.916	3.926	3.969	53	53	203.610	344	1	8	- 0,39

18	3.187	3.320	3.926	739	739	222.634	366	23	9	1,65
19	3.320	3.320	3.320	- 0	0	210.917	347	0	9	1,75
20	2.530	2.672	3.320	790	790	231.563	369	31	10	3,78
21	2.374	2.427	2.672	298	298	224.779	366	13	10	4,63
22	3.236	3.090	2.427	- 808	808	244.249	386	25	11	2,30
23	3.683	3.576	3.090	- 593	593	248.912	395	16	11	0,74
24	3.215	3.280	3.576	361	361	243.977	394	11	11	1,66

α	0,82

Otimização do modelo de Holt

Período *t*	**Demanda D_t**	**Nível L_t**	**Tendência T_t**	**Previsão F_t**	**Erro E_t**	**Erro Absoluto A_t**	**MSE_t**	**MAD_t**	**% de Erro**	**$MAPE_t$**	**SA_t**
0		4.485	- 54								
1	4.060	4.251	- 54	4.432	372	372	138.429	372	9	9	1
2	4.223	4.210	- 54	4.197	- 25	25	69.540	199	1	5	2
3	4.177	4.166	- 54	4.156	- 21	21	46.510	140	1	3	2
4	3.507	3.818	- 54	4.113	605	605	126.483	256	17	7	4
5	3.802	3.783	- 54	3.764	- 38	38	101.473	212	1	6	4
6	3.623	3.678	- 54	3.729	106	106	86.431	195	3	5	5,13
7	4.757	4.176	- 54	3.624	- 1.133	1.133	257.467	329	24	8	- 0,41
8	5.050	4.574	- 54	4.123	- 927	927	332.789	404	18	9	- 2,63

9	4.141	4.336	- 54	4.521	380	380	311.843	401	9	9	- 1,70
10	4.282	4.282	- 54	4.282	0	0	280.659	361	0	8	- 1,89
11	4.652	4.435	- 54	4.229	- 423	423	271.449	367	9	8	- 3,02
12	4.056	4.223	- 54	4.382	326	326	257.669	363	8	8	- 2,15
13	3.892	4.034	- 54	4.169	278	278	243.772	357	7	8	- 1,41
14	3.773	3.880	- 54	3.981	208	208	229.436	346	5	8	- 0,85
15	4.205	4.010	- 54	3.826	- 379	379	223.698	348	9	8	- 1,93
16	3.933	3.945	- 54	3.957	24	24	209.753	328	1	8	- 1,98
17	3.916	3.904	- 54	3.892	- 24	24	197.450	310	1	7	- 2,17
18	3.187	3.527	- 54	3.850	663	663	210.932	330	21	8	- 0,03
19	3.320	3.399	- 54	3.473	154	154	201.073	320	5	8	0,45
20	2.530	2.948	- 54	3.345	815	815	224.242	345	32	9	2,78
21	2.374	2.641	- 54	2.894	521	521	226.480	353	22	10	4,19
22	3.236	2.903	- 54	2.587	- 648	648	235.290	367	20	10	2,27
23	3.683	3.255	- 54	2.849	- 833	833	255.258	387	23	11	- 0,01
24	3.215	3.208	- 54	3.202	- 13	13	244.629	372	0	10	- 0,04

α	0,49
β	-

Otimização do modelo de Winter

Período t	Demanda D_t	Nível L_t	Tendência T_t	Fator Sazonal S_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
		4.660	- 66									
1	4.060	4.594	- 66	0,94	4.311	252	252	63.307	252	6	6	1
2	4.223	4.528	- 66	0,96	4.365	142	142	41.747	197	3	5	2
3	4.177	4.462	- 66	1,09	4.862	685	685	184.013	359	16	9	3
4	3.507	4.396	- 66	0,99	4.364	856	856	321.205	484	24	13	4
5	3.802	4.330	- 66	0,94	4.064	261	261	270.629	439	7	11	5
6	3.623	4.264	- 66	0,96	4.110	487	487	265.021	447	13	12	6
7	4.757	4.198	- 66	1,09	4.574	- 183	183	231.952	409	4	11	6,11
8	5.050	4.132	- 66	0,99	4.101	- 949	949	315.417	477	19	12	3,25
9	4.141	4.066	- 66	0,94	3.816	- 325	325	292.115	460	8	11	2,66
10	4.282	4.000	- 66	0,96	3.856	- 427	427	281.099	457	10	11	1,75
11	4.652	3.934	- 66	1,09	4.286	- 366	366	267.713	448	8	11	0,97
12	4.056	3.868	- 66	0,99	3.839	- 216	216	249.306	429	5	10	0,51
13	3.892	3.802	- 66	0,94	3.568	- 324	324	238.190	421	8	10	- 0,25
14	3.773	3.736	- 66	0,96	3.601	- 172	172	223.287	403	5	10	- 0,69
15	4.205	3.670	- 66	1,09	3.999	- 206	206	211.229	390	5	9	- 1,24
16	3.933	3.604	- 66	0,99	3.577	- 355	355	205.923	388	9	9	- 2,17
17	3.916	3.538	- 66	0,94	3.320	- 596	596	214.689	400	15	10	- 3,59
18	3.187	3.472	- 66	0,96	3.347	160	160	204.186	387	5	10	- 3,30
19	3.320	3.406	- 66	1,09	3.711	391	391	201.502	387	12	10	- 2,29
20	2.530	3.340	- 66	0,99	3.315	785	785	222.274	407	31	11	- 0,24

21	2.374	3.274	- 66	0,94	3.073	699	699	234.956	421	29	12	1,43
22	3.236	3.208	- 66	0,96	3.092	- 143	143	225.208	408	4	11	1,12
23	3.683	3.142	- 66	1,09	3.423	- 259	259	218.343	402	7	11	0,49
24	3.215	3.076	- 66	0,99	3.053	- 162	162	210.334	392	5	11	0,09
25				0,94	2.825							
26				0,96	2.838							
27				1,09	3.136							
28				0,99	2.791							

α	-
β	0,01
γ	-

APÊNDICE B – Otimização MAPE

Otimização do modelo AES

Período t	Demanda D_t	Nível L_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
0		3.816								
1	4.060	4.016	3.816	- 243	243	59.250	243	6	6	- 1,00
2	4.223	4.185	4.016	- 207	207	50.971	225	5	5	- 2,00
3	4.177	4.179	4.185	8	8	34.003	153	0	4	- 2,89
4	3.507	3.628	4.179	671	671	138.125	282	19	8	0,81
5	3.802	3.771	3.628	- 174	174	116.550	261	5	7	0,21
6	3.623	3.650	3.771	148	148	100.753	242	4	6	0,84
7	4.757	4.558	3.650	- 1.107	1.107	261.502	365	23	9	- 2,47
8	5.050	4.961	4.558	- 492	492	259.087	381	10	9	- 3,66
9	4.141	4.289	4.961	820	820	305.083	430	20	10	- 1,34
10	4.282	4.283	4.289	6	6	274.578	388	0	9	- 1,47
11	4.652	4.586	4.283	- 369	369	261.983	386	8	9	- 2,43
12	4.056	4.151	4.586	530	530	263.563	398	13	9	- 1,03
13	3.892	3.939	4.151	259	259	248.465	387	7	9	- 0,38
14	3.773	3.803	3.939	165	165	232.671	371	4	9	0,04
15	4.205	4.132	3.803	- 402	402	227.921	373	10	9	- 1,03
16	3.933	3.969	4.132	200	200	216.165	363	5	9	- 0,51
17	3.916	3.926	3.969	53	53	203.612	344	1	8	- 0,39

18	3.187	3.320	3.926	739	739	222.636	366	23	9	1,65
19	3.320	3.320	3.320	- 0	0	210.918	347	0	9	1,75
20	2.530	2.672	3.320	790	790	231.564	369	31	10	3,78
21	2.374	2.427	2.672	298	298	224.779	366	13	10	4,63
22	3.236	3.090	2.427	- 808	808	244.250	386	25	11	2,30
23	3.683	3.576	3.090	- 593	593	248.912	395	16	11	0,74
24	3.215	3.280	3.576	361	361	243.978	394	11	11	1,66

α	0,82

Otimização do modelo de Holt

Período *t*	**Demanda D_t**	**Nível L_t**	**Tendência T_t**	**Previsão F_t**	**Erro E_t**	**Erro Absoluto A_t**	**MSE_t**	**MAD_t**	**% de Erro**	**$MAPE_t$**	**SA_t**
0		4.485	- 54								
1	4.060	4.432	- 54	4.432	372	372	138.429	372	9	9	1
2	4.223	4.378	- 54	4.378	156	156	81.342	264	4	6	2
3	4.177	4.325	- 54	4.325	148	148	61.491	225	4	5	3
4	3.507	4.271	- 54	4.271	764	764	191.967	360	22	10	4
5	3.802	4.218	- 54	4.218	416	416	188.105	371	11	10	5
6	3.623	4.164	- 54	4.164	541	541	205.510	399	15	11	6,00
7	4.757	4.111	- 54	4.111	- 646	646	235.854	435	14	11	4,02
8	5.050	4.057	- 54	4.057	- 993	993	329.570	504	20	12	1,50
9	4.141	4.004	- 54	4.004	- 137	137	295.046	464	3	11	1,34
10	4.282	3.950	- 54	3.950	- 332	332	276.571	450	8	11	0,64

11	4.652	3.897	- 54	3.897	- 756	756	303.331	478	16	11	- 0,98
12	4.056	3.843	- 54	3.843	- 213	213	281.824	456	5	11	- 1,49
13	3.892	3.790	- 54	3.790	- 102	102	260.949	429	3	10	- 1,83
14	3.773	3.736	- 54	3.736	- 37	37	242.408	401	1	10	- 2,05
15	4.205	3.683	- 54	3.683	- 522	522	244.421	409	12	10	- 3,28
16	3.933	3.629	- 54	3.629	- 304	304	234.911	402	8	10	- 4,09
17	3.916	3.576	- 54	3.576	- 341	341	227.917	399	9	10	- 4,98
18	3.187	3.522	- 54	3.522	335	335	221.503	395	11	10	- 4,18
19	3.320	3.468	- 54	3.468	149	149	211.010	382	4	9	- 3,93
20	2.530	3.415	- 54	3.415	885	885	239.630	407	35	11	- 1,52
21	2.374	3.361	- 54	3.361	988	988	274.688	435	42	12	0,85
22	3.236	3.308	- 54	3.308	72	72	262.441	419	2	12	1,06
23	3.683	3.254	- 54	3.254	- 428	428	259.012	419	12	12	0,03
24	3.215	3.201	- 54	3.201	- 14	14	248.228	402	0	11	- 0,00

α	-
β	-

Otimização do modelo de Winter

Período t	Demanda D_t	Nível L_t	Tendência T_t	Fator Sazonal S_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
		4.660	- 66									
1	4.060	4.353	- 66	0,94	4.311	252	252	63.307	252	6	6	1
2	4.223	4.371	- 66	0,96	4.132	- 90	90	35.722	171	2	4	1
3	4.177	3.881	- 66	1,09	4.691	514	514	111.738	285	12	7	2
4	3.507	3.562	- 66	0,99	3.787	280	280	103.373	284	8	7	3
5	3.802	3.995	- 66	0,94	3.281	- 521	521	137.027	331	14	8	1
6	3.623	3.776	- 66	0,96	3.788	164	164	118.681	303	5	8	2
7	4.757	4.300	- 66	1,09	4.043	- 715	715	174.684	362	15	9	- 0,32
8	5.050	5.001	- 66	0,99	4.202	- 848	848	242.637	423	17	10	- 2,28
9	4.141	4.465	- 66	0,94	4.632	491	491	242.421	430	12	10	- 1,10
10	4.282	4.438	- 66	0,96	4.241	- 42	42	218.353	391	1	9	- 1,32
11	4.652	4.280	- 66	1,09	4.764	112	112	199.634	366	2	9	- 1,10
12	4.056	4.099	- 66	0,99	4.183	127	127	184.345	346	3	8	- 0,80
13	3.892	4.135	- 66	0,94	3.785	- 107	107	171.045	328	3	8	- 1,17
14	3.773	3.930	- 66	0,96	3.923	149	149	160.423	315	4	7	- 0,74
15	4.205	3.860	- 66	1,09	4.210	5	5	149.731	294	0	7	- 0,78
16	3.933	3.945	- 66	0,99	3.765	- 167	167	142.123	286	4	7	- 1,38
17	3.916	4.143	- 66	0,94	3.640	- 276	276	138.234	286	7	7	- 2,35
18	3.187	3.384	- 66	0,96	3.930	743	743	161.255	311	23	8	0,23
19	3.320	3.074	- 66	1,09	3.615	295	295	157.361	310	9	8	1,18
20	2.530	2.595	- 66	0,99	2.986	456	456	159.895	318	18	8	2,59

21	2.374	2.529	- 66	0,94	2.374	- 0	0	152.281	303	0	8	2,72
22	3.236	3.266	- 66	0,96	2.374	- 861	861	179.069	328	27	9	- 0,12
23	3.683	3.362	- 66	1,09	3.487	- 196	196	172.954	322	5	9	- 0,73
24	3.215	3.245	- 66	0,99	3.272	57	57	165.881	311	2	8	- 0,57
25				0,94	2.983							
26				0,96	3.000							
27				1,09	3.320							
28				0,99	2.959							

α	0,90
β	-
γ	-

APÊNDICE C – Otimização MSE

Otimização do modelo AES

Período t	Demanda D_t	Nível L_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
0		3.816								
1	4.060	3.987	3.816	- 243	243	59.250	243	6	6	- 1,00
2	4.223	4.152	3.987	- 236	236	57.411	240	6	6	- 2,00
3	4.177	4.170	4.152	- 25	25	38.486	168	1	4	- 3,00
4	3.507	3.706	4.170	662	662	138.474	292	19	8	0,54
5	3.802	3.773	3.706	- 96	96	112.636	253	3	7	0,24
6	3.623	3.668	3.773	150	150	97.613	235	4	6	0,90
7	4.757	4.431	3.668	- 1.089	1.089	253.044	357	23	9	- 2,46
8	5.050	4.864	4.431	- 619	619	269.316	390	12	9	- 3,84
9	4.141	4.358	4.864	723	723	297.553	427	17	10	- 1,81
10	4.282	4.305	4.358	75	75	268.368	392	2	9	- 1,78
11	4.652	4.548	4.305	- 347	347	254.940	388	7	9	- 2,69
12	4.056	4.203	4.548	492	492	253.895	397	12	9	- 1,39
13	3.892	3.985	4.203	312	312	241.829	390	8	9	- 0,62
14	3.773	3.837	3.985	212	212	227.768	377	6	9	- 0,08
15	4.205	4.094	3.837	- 368	368	221.612	377	9	9	- 1,05
16	3.933	3.981	4.094	162	162	209.393	363	4	9	- 0,65
17	3.916	3.936	3.981	65	65	197.325	346	2	8	- 0,49

18	3.187	3.411	3.936	749	749	217.528	368	24	9	1,57
19	3.320	3.347	3.411	91	91	206.519	354	3	9	1,90
20	2.530	2.775	3.347	817	817	229.585	377	32	10	3,95
21	2.374	2.494	2.775	401	401	226.315	378	17	10	5,00
22	3.236	3.013	2.494	- 742	742	241.033	394	23	11	2,91
23	3.683	3.482	3.013	- 670	670	250.048	406	18	11	1,17
24	3.215	3.295	3.482	267	267	242.607	401	8	11	1,86

α	0,70

Otimização do modelo de Holt

Período *t*	**Demanda D_t**	**Nível L_t**	**Tendência T_t**	**Previsão F_t**	**Erro E_t**	**Erro Absoluto A_t**	**MSE_t**	**MAD_t**	**% de Erro**	**$MAPE_t$**	**SA_t**
0		4.485	- 54								
1	4.060	4.187	- 54	4.432	372	372	138.429	372	9	9	1
2	4.223	4.192	- 54	4.133	- 89	89	73.195	231	2	6	1
3	4.177	4.164	- 54	4.139	- 39	39	49.294	167	1	4	1
4	3.507	3.713	- 54	4.110	603	603	127.873	276	17	7	3
5	3.802	3.754	- 54	3.660	- 142	142	106.348	249	4	7	3
6	3.623	3.650	- 54	3.700	77	77	89.605	220	2	6	3,55
7	4.757	4.361	- 54	3.596	- 1.161	1.161	269.403	355	24	9	- 1,07
8	5.050	4.796	- 54	4.307	- 743	743	304.722	403	15	9	- 2,78
9	4.141	4.347	- 54	4.743	602	602	311.089	425	15	10	- 1,22
10	4.282	4.286	- 54	4.293	11	11	279.992	384	0	9	- 1,33

11	4.652	4.509	- 54	4.232	- 420	420	270.562	387	9	9	- 2,40
12	4.056	4.192	- 54	4.455	399	399	261.315	388	10	9	- 1,37
13	3.892	3.976	- 54	4.139	247	247	245.904	377	6	9	- 0,75
14	3.773	3.824	- 54	3.923	150	150	229.936	361	4	8	- 0,37
15	4.205	4.056	- 54	3.771	- 434	434	227.164	366	10	9	- 1,55
16	3.933	3.957	- 54	4.003	70	70	213.273	347	2	8	- 1,43
17	3.916	3.912	- 54	3.903	- 13	13	200.737	328	0	8	- 1,56
18	3.187	3.416	- 54	3.858	672	672	214.640	347	21	8	0,46
19	3.320	3.334	- 54	3.363	43	43	203.439	331	1	8	0,62
20	2.530	2.786	- 54	3.281	751	751	221.464	352	30	9	2,71
21	2.374	2.496	- 54	2.733	359	359	217.064	352	15	9	3,73
22	3.236	2.965	- 54	2.443	- 793	793	235.760	372	24	10	1,40
23	3.683	3.419	- 54	2.911	- 772	772	251.400	390	21	11	- 0,64
24	3.215	3.266	- 54	3.366	151	151	241.873	380	5	10	- 0,26

α	0,66
β	-

Otimização do modelo de Winter

Período t	Demanda D_t	Nível L_t	Tendência T_t	Fator Sazonal S_t	Previsão F_t	Erro E_t	Erro Absoluto A_t	MSE_t	MAD_t	% de Erro	$MAPE_t$	SA_t
		4.660	- 66									
1	4.060	4.594	- 66	0,94	4.311	252	252	63.307	252	6	6	1
2	4.223	4.528	- 66	0,96	4.365	142	142	41.747	197	3	5	2
3	4.177	4.462	- 66	1,09	4.862	685	685	184.013	359	16	9	3
4	3.507	4.396	- 66	0,99	4.364	856	856	321.205	484	24	13	4
5	3.802	4.330	- 66	0,94	4.064	261	261	270.629	439	7	11	5
6	3.623	4.264	- 66	0,96	4.110	487	487	265.021	447	13	12	6
7	4.757	4.198	- 66	1,09	4.574	- 183	183	231.952	409	4	11	6,11
8	5.050	4.132	- 66	0,99	4.101	- 949	949	315.417	477	19	12	3,25
9	4.141	4.066	- 66	0,94	3.816	- 325	325	292.115	460	8	11	2,66
10	4.282	4.000	- 66	0,96	3.856	- 427	427	281.099	457	10	11	1,75
11	4.652	3.934	- 66	1,09	4.286	- 366	366	267.713	448	8	11	0,97
12	4.056	3.868	- 66	0,99	3.839	- 216	216	249.306	429	5	10	0,51
13	3.892	3.802	- 66	0,94	3.568	- 324	324	238.190	421	8	10	- 0,25
14	3.773	3.736	- 66	0,96	3.601	- 172	172	223.287	403	5	10	- 0,69
15	4.205	3.670	- 66	1,09	3.999	- 206	206	211.229	390	5	9	- 1,24
16	3.933	3.604	- 66	0,99	3.577	- 355	355	205.923	388	9	9	- 2,17
17	3.916	3.538	- 66	0,94	3.320	- 596	596	214.689	400	15	10	- 3,59
18	3.187	3.472	- 66	0,96	3.347	160	160	204.186	387	5	10	- 3,30
19	3.320	3.406	- 66	1,09	3.711	391	391	201.502	387	12	10	- 2,29
20	2.530	3.340	- 66	0,99	3.315	785	785	222.274	407	31	11	- 0,24

21	2.374	3.274	- 66	0,94	3.073	699	699	234.956	421	29	12	1,43
22	3.236	3.208	- 66	0,96	3.092	- 143	143	225.208	408	4	11	1,12
23	3.683	3.142	- 66	1,09	3.423	- 259	259	218.343	402	7	11	0,49
24	3.215	3.076	- 66	0,99	3.053	- 162	162	210.334	392	5	11	0,09
25				0,94	2.825							
26				0,96	2.838							
27				1,09	3.136							
28				0,99	2.791							

α	-
β	0,01
γ	-

APÊNDICE D – Otimização utilizando o software Action Stat

Otimização do modelo AES

SUAVIZAÇÃO EXPONENCIAL - SUAVIZAÇÃO SIMPLES

Resultados da Análise

Medidas de Acurácia	
MAPE	10,728
MAD	387,868
MSD	239187,882

Constantes da Suavização	
Nível	0,690

Dados	*Ajuste*	*Residuos*
4059,78	*4089,24*	*-29,46*
4222,58	4068,91	153,67
4177,19	4174,96	2,23
3507,48	4176,50	-669,02
3802,24	3714,79	87,45
3623,38	3775,14	-151,76
4757,19	3670,41	1086,78
5049,97	4420,43	629,54
4140,98	4854,90	-713,92
4282,27	4362,20	-79,93
4652,25	4307,04	345,21
4055,82	4545,28	-489,46
3891,84	4207,49	-315,65
3773,13	3989,65	-216,52
4204,68	3840,22	364,46
3932,81	4091,75	-158,94
3916,12	3982,06	-65,94
3186,65	3936,55	-749,90
3319,70	3419,02	-99,32
2529,86	3350,48	-820,62
2373,60	2784,14	-410,54
3235,50	2500,81	734,69
3682,87	3007,85	675,02
3214,90	3473,70	-258,80

Previsões		
Limite Inferior da Previsão	*Previsão*	*Limite Superior da Previsão*
2336,54	3295,09	4253,65
2130,42	3295,09	4459,76
1955,66	3295,09	4634,53
1801,20	3295,09	4788,98
1661,29	3295,09	4928,90
1532,44	3295,09	5057,75

Otimização do modelo de Holt

SUAVIZAÇÃO EXPONENCIAL - SUAVIZAÇÃO DE HOLT

Resultados da Análise

Medidas de Acurácia	
MAPE	10,525
MAD	383,853
MSD	237654,130

Constantes da Suavização	
Nível	0,655
Tendência	0,000

Dados	*Ajuste*	*Nível*	*Tendência*	*Residuos*
4059,78	*3957,78*	*4024,62*	*-30,26*	*102,00*
4222,58	3994,36	4143,92	-30,24	228,22
4177,19	4113,68	4155,30	-30,23	63,51
3507,48	4125,07	3720,35	-30,29	-617,59
3802,24	3690,05	3763,57	-30,28	112,19
3623,38	3733,29	3661,26	-30,29	-109,91
4757,19	3630,97	4369,01	-30,18	1126,22
5049,97	4338,83	4804,85	-30,11	711,14
4140,98	4774,74	4359,42	-30,17	-633,76
4282,27	4329,25	4298,46	-30,18	-46,98
4652,25	4268,28	4519,91	-30,14	383,97
4055,82	4489,77	4205,39	-30,18	-433,95
3891,84	4175,21	3989,51	-30,21	-283,37
3773,13	3959,30	3837,30	-30,23	-186,17
4204,68	3807,07	4067,63	-30,19	397,61
3932,81	4037,44	3968,87	-30,20	-104,63
3916,12	3938,67	3923,89	-30,20	-22,55
3186,65	3893,69	3430,35	-30,27	-707,04

3319,70	3400,08	3347,40	-30,28	-80,38
2529,86	3317,12	2801,21	-30,36	-787,26
2373,60	2770,85	2510,52	-30,40	-397,25
3235,50	2480,12	2975,14	-30,32	755,38
3682,87	2944,81	3428,48	-30,25	738,06
3214,90	3398,23	3278,09	-30,27	-183,33

	Previsões	
Limite Inferior da Previsão	*Previsão*	*Limite Superior da Previsão*
2292,34	3247,82	4203,30
2075,08	3217,55	4360,02
1884,34	3187,28	4490,22
1711,26	3157,01	4602,76
1551,04	3126,74	4702,45
1400,71	3096,47	4792,24

Otimização do modelo de Winter

SUAVIZAÇÃO EXPONENCIAL - SUAVIZAÇÃO DE HOLT-WINTERS

Resultados da Análise

Medidas de Acurácia	
MAPE	7,183
MAD	262,094
MSD	141298,264

Constantes da Suavização	
Nível	0,886
Tendência	0,048
Sazonalidade	1,000

Dados	*Ajuste*	*Nível*	*Tendência*	*Sazonalidade*	*Residuos*
4372,38					
4365,90					
3913,33					
3583,59	3753,01	3801,95	77,15	0,97	-169,43
3988,52	4039,11	3723,98	69,68	1,06	-50,59
3774,73	3696,27	3751,58	67,65	0,97	78,46
4323,73	3812,78	3891,04	71,11	0,96	510,95
5005,17	4812,08	4432,46	93,75	1,06	193,09
4455,14	4645,44	4687,08	101,50	0,97	-190,30

4452,33	4592,47	4614,83	93,13	0,98	-140,14
4259,76	4984,49	4580,71	87,01	1,07	-724,73
4052,77	3981,92	4066,58	58,07	0,97	70,85
4153,84	4131,71	4189,65	61,20	0,97	22,13
3954,35	4539,02	4271,01	62,17	1,05	-584,67
3858,16	3750,48	3838,79	38,36	0,97	107,67
3907,20	3908,60	3975,75	43,11	0,97	-1,40
4123,18	4182,87	4017,58	43,05	1,03	-59,68
3468,45	3930,11	4009,31	40,58	0,97	-461,66
3107,16	3548,56	3628,51	20,29	0,97	-441,40
2601,74	3339,96	3246,79	0,94	1,03	-738,22
2498,82	2468,31	2611,90	-29,68	0,96	30,50
3326,22	2471,12	2610,49	-28,32	0,96	855,10
3415,78	3370,24	3373,62	9,79	1,00	45,53
3316,13	3288,66	3423,89	11,74	0,96	27,47

	Previsões	
Limite Inferior da Previsão	***Previsão***	***Limite Superior da Previsão***
2686,35	3425,21	4164,07
2464,97	3478,71	4492,44
2392,60	3353,38	4314,17
2142,21	3463,55	4784,89
1984,89	3517,50	5050,11
1937,58	3390,64	4843,71