



PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA DE PROCESSOS
MESTRADO PROFISSIONAL

UM MODELO DE PREVISÃO DE VENDAS EM UMA EMPRESA DE MÉDIO PORTE NA CIDADE DE MANAUS – UM ESTUDO DE CASO

Vera Lucia Assis da Fonseca

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Engenharia de Processos – Mestrado Profissional, PPGEP/ITEC, da Universidade Federal do Pará, como parte dos requisitos necessários à obtenção do título de Mestre em Engenharia de Processos.

Orientador: Rui Nelson Otoni Magno

Belém

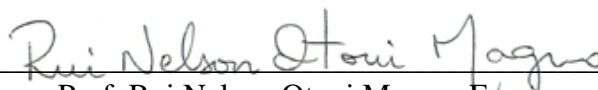
Fevereiro de 2022

**UM MODELO DE PREVISÃO DE VENDAS EM UMA EMPRESA DE MÉDIO
PORTE NA CIDADE DE MANAUS – UM ESTUDO DE CASO**

Vera Lúcia Assis da Fonseca

DISSERTAÇÃO SUBMETIDA AO CORPO DOCENTE DO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA PROCESSOS – MESTRADO PROFISSIONAL (PPGEP/ITEC) DA UNIVERSIDADE FEDERAL DO PARÁ COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE MESTRE EM ENGENHARIA DE PROCESSOS.

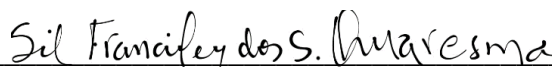
Examinada por:



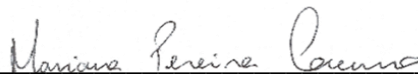
Prof. Rui Nelson Otoni Magno, Eng.
(PPGEP/ITEC/UFPA-Orientador)



Prof. Josiel Lobato Ferreira, Dr.
(PPGEP/ITEC/UFPA-Coorientador)



Prof. Sil Franciley dos Santos Quaresma, Dr.
(PPGEP/ITEC/UFPA-Membro)



Profa. Mariana Pereira Carneiro, Dra.
(UEPA-Membro)

BELÉM, PA - BRASIL

FEVEREIRO DE 2022

Dados Internacionais de Catalogação-na-Publicação (CIP)
Sistema de Bibliotecas da UFPA

Fonseca, Vera Lucia Assis da, 1969-

Um modelo de previsão de vendas em uma empresa de médio porte na cidade de Manaus - Um estudo de caso / Vera Lucia Assis da Fonseca - 2022.

Orientador: Rui Nelson Otoni Magno

Dissertação (Mestrado Profissional) - Universidade Federal do Pará. Instituto de Tecnologia. Programa de Pós-Graduação em Engenharia de Processos, 2022.

1. Previsão de vendas 2. Processo 3. Acuracidade 4. Modelo de previsão I. Título

CDD 670.42

*Dedico este trabalho a minha mãe,
Altina Fonseca, que tanto me incentivou
a ir além.*

AGRADECIMENTOS

Ao meu orientador, pelo acompanhamento durante as pesquisas experimentais e pela assistência na elaboração desta dissertação.

Aos professores e colegas do PPGEF.

*“A educação é a arma mais poderosa que
você pode usar para mudar o mundo...”*

(Nelson Mandela)

Resumo da Dissertação apresentada ao PPGEP/UFPA como parte dos requisitos necessários para a obtenção do grau de Mestre em Engenharia de Processos (M. Eng.)

UM MODELO DE PREVISÃO DE VENDAS EM UMA EMPRESA DE MÉDIO PORTE NA CIDADE DE MANAUS – UM ESTUDO DE CASO

Vera Lucia Assis da Fonseca

Fevereiro/2022

Orientador: Rui Nelson Otoni Magno

Área de Concentração: Engenharia de Processos

O processo de previsão de vendas vem se estruturando ao longo do tempo com novas tecnologias e ferramentas, para consolidação e manuseio de dados. As empresas, que antes não possuíam foco no processo de previsão de vendas, não se viam impactadas pela falta dele, mas, atualmente, adequações são necessárias para a inserção do mesmo, pois há consenso de que somente a intuitividade, normalmente direcionada por experiências passadas ou subjetividades, ou otimizavam resultados ou os subestimavam. Caminhando no exposto, esta pesquisa visa identificar um modelo de previsão de vendas adequado ao portfólio de uma empresa de bebidas de médio porte. No estudo desta dissertação foi aplicada a técnica de pesquisa explicativa com análises exploratórias e descritivas, também foram utilizados os softwares Minitab® e Excel® para realizar as análises através de resumos estatísticos, tabelas e figuras, para que houvesse a escolha assertiva do modelo para ser aplicado ao negócio. Foram avaliados modelos de previsão qualitativos e quantitativos, análise gráfica, de resíduos e cálculos de erro de previsão. Foram comparados os desvios médios e os MAPEs (*Mean Absolute Percent Error*) dos modelos: média móvel, suavização exponencial, tendência linear e holt winter e, como conclusão, os modelos com menores erros de previsão foram: média móvel N=2 com MAPE=14,8%, suavização exponencial com MAPE=15,2% e tendência linear com MAPE=15,4%. A escolha foi pelo modelo de suavização exponencial, apesar de não ser o menor erro é de fácil aplicação e pondera os dados históricos.

Abstract of Dissertation presented to PPGE/UFPA as a partial fulfillment of the requirements for the degree of Master in Process Engineering (M. Eng.)

**A SALES FORECAST MODEL IN A MEDIUM-SIZED COMPANY IN THE
CITY OF MANAUS – A CASE STUDY**

Vera Lucia Assis da Fonseca

February/2022

Advisor: Rui Nelson Otoni Magno

Research Area: Process Engineering

The sales forecasting process has been structured over time with new technologies and tools, for data consolidation and handling. The companies, which previously had no focus on the sales forecasting process, were not impacted by the lack of it, but currently, adjustments are necessary for its insertion, because there is consensus that only intuitivity, usually directed by past experiences or subjectivities, or optimized results or underestimated them. Walking in the above, this research aims to identify a sales forecast model appropriate to the portfolio of a medium-sized beverage company. In the study of this dissertation, the explanatory research technique was applied with exploratory and descriptive analyses, and minitab® and Excel software was also used® to perform the analyses through statistical abstracts, tables and figures, so that there was the assertive choice of the model to be applied to the business. Qualitative and quantitative forecastmodels, graphic analysis, residue scans and forecast error calculations were evaluated. The mean deviations and MAPEs (Mean Absolute Percent Error) of the models were compared: moving average, exponential smoothing, linear trend and holt winter and, as conclusion, the models with the lowest prediction errors were: moving average $N=2$ with $MAPE=14.8\%$, exponential smoothing with $MAPE=15.2\%$ and linear trend with $MAPE=15.4\%$. The choice was for the exponential smoothing model, although not the slightest error is easy to apply and weights the historical data.

SUMÁRIO

CAPÍTULO 1 - INTRODUÇÃO.....	1
1.1 - MOTIVAÇÃO.....	1
1.2 - OBJETIVOS.....	4
1.2.1 - Objetivo geral.....	4
1.2.2 - Objetivos específicos.....	4
1.3 - CONTRIBUIÇÃO PARA DISSERTAÇÃO.....	4
1.4 - ORGANIZAÇÃO DO TRABALHO.....	5
CAPÍTULO 2 - REVISÃO DA LITERATURA.....	7
2.1 - PREVISÃO DE VENDAS.....	7
2.2 - O PROCESSO DE PREVISÃO DE VENDAS.....	8
2.3 - MÉTODOS UTILIZADOS PARA DE PREVISÃO DE VENDAS.....	12
2.3.1 - Métodos qualitativos.....	14
2.3.2 - Métodos quantitativos.....	15
2.3.2.1 - Modelos de séries temporais.....	17
2.3.2.2 - Modelo causal.....	22
2.3.3 - Erros de previsão.....	23
2.3.4 - Controle do modelo de previsão.....	25
2.4 - ANÁLISE DE RESÍDUOS.....	25
2.5 - APLICAÇÕES.....	26
CAPÍTULO 3 - MATERIAIS E MÉTODOS.....	32
3.1 - SITUAÇÃO ATUAL DO OBJETO DE ESTUDO.....	32
3.2 - ETAPA INICIAL PARA AJUSTE DO PROCESSO.....	34
3.3 - ESCOLHA DO MODELO DE PREVISÃO.....	35
CAPÍTULO 4 - RESULTADOS E DISCUSSÃO.....	37
4.1 - RESULTADOS ALCANÇADOS.....	37
4.1.1 - Média móvel.....	37
4.1.2 - Suavização exponencial simples.....	42
4.1.3 - Suavização exponencial dupla.....	45
4.1.4 - Tendência linear.....	47
4.1.5 - Holt Winters.....	49
4.1.6 - Comparativo entre os modelos de previsão.....	51

4.2 - PROCESSO DE PREVISÃO DE VENDAS AJUSTADO.....	51
CAPÍTULO 5 - CONCLUSÕES E SUGESTÕES.....	54
5.1 - CONCLUSÕES.....	54
5.2 - SUGESTÕES.....	55
REFERÊNCIAS BIBLIOGRÁFICAS.....	56

LISTA DE FIGURAS

Figura 1.1	Indicadores de assertividade.....	3
Figura 2.1	Sistema genérico de previsão de vendas.....	10
Figura 2.2	Noventa tipos de estimativa de demanda (6x5x3).....	11
Figura 2.3	Processo de gestão de demanda.....	12
Figura 2.4	Técnicas estatísticas.....	13
Figura 2.5	Principais categorias de modelo de previsão.....	16
Figura 2.6	Projetando as vendas futuras com base em dados do passado.....	21
Figura 2.7	Padrões de demanda.....	21
Figura 2.8	Gráfico sequencial para estudo da configuração dos erros individuais de previsão.....	26
Figura 2.9	Metodologia proposta para seleção de métodos de previsão de demanda.....	29
Figura 3.1	Processo atual de planejamento da empresa em análise.....	33
Figura 4.1	Comparativo entre real e previsto – Média móvel N=2.....	37
Figura 4.2	Comparativo entre real e previsto – Média móvel N=3.....	38
Figura 4.3	Comparativo entre real e previsto – Média móvel N=4.....	39
Figura 4.4	Gráfico de resíduos – Média móvel – N=2.....	41
Figura 4.5	Gráfico de resíduos – Média móvel – N=3.....	41
Figura 4.6	Gráfico de resíduos – Média móvel – N=4.....	42
Figura 4.7	Comparativo real <i>versus</i> previsto – Suavização exponencial.....	43
Figura 4.8	Gráfico resíduo – Suavização exponencial.....	44
Figura 4.9	Comparativo real <i>versus</i> previsto – Suavização exponencial dupla.....	45
Figura 4.10	Gráfico resíduo – Suavização exponencial dupla.....	46
Figura 4.11	Análise de tendência para P2L.....	48
Figura 4.12	Resíduos – Tendência linear P2L.....	48
Figura 4.13	Saída de dados método Holt Winters.....	50
Figura 4.14	Resíduos do método Holt Winters.....	50
Figura 4.15	Processo mensal de previsão de vendas resumido – Ajustado.....	53

LISTA DE TABELAS

Tabela 2.1	Métodos estatísticos e horizontes.....	16
Tabela 2.2	Análise de erros obtidos pelos métodos de previsão de demanda.....	27
Tabela 2.3	Comparação da acurácia entre os modelos de previsão de vendas para os produtos analisados.....	31
Tabela 3.1	Áreas e necessidades – Resumo do levantamento.....	34
Tabela 4.1	Saída de dados para média móvel para N=2.....	38
Tabela 4.2	Saída de dados para média móvel para N=3.....	39
Tabela 4.3	Saída de dados para média móvel para N=4.....	40
Tabela 4.4	Saída de dados de suavização exponencial.....	44
Tabela 4.5	Saída de dados de suavização exponencial dupla.....	46
Tabela 4.6	Saída de dados tendência linear.....	47
Tabela 4.7	Constantes de suavização.....	49
Tabela 4.8	Saída de dados Holt Winters.....	49
Tabela 4.9	Comparativo entre os modelos.....	51

NOMENCLATURA

CFE	CUMULATIVE SUM OF FORECAST ERRORS
DAM	DESVIO ABSOLUTO MÉDIO
EME	ERRO MÉDIO EXPONENCIAL
ILOS	INSTITUTO DE LOGÍSTICA E SUPPLY CHAIN
MAD	MEAN ABSOLUTE DEVIATION
MAPE	MEAN ABSOLUTE PERCENT ERROR
MMS	MÉDIA MÓVEL SIMPLES
MPE	MEAN PERCENT ERRO
MSE	MEAN SQUARED ERROR
RMSE	ROOT MEAN SQUARE ERROR
SKU	STOCK KEEPING UNIT
TR	TRIGG SIGNAL
TS	TRACKING SIGNAL
α	ALPHA
Σ	SIGMA
δ	DELTA

CAPÍTULO 1

INTRODUÇÃO

1.1 - MOTIVAÇÃO

Qualquer que seja o grau de sofisticação do processo de previsão numa empresa, é sempre difícil utilizar dados históricos para prever futuras tendências, ciclos ou sazonalidades. Apesar das dificuldades, muitas empresas não têm alternativa – devem obrigatoriamente fazer previsões (SLACK *et al.*, 2009).

As empresas buscam aumentar sua rentabilidade e produtividade através de um modelo estruturado envolvendo várias áreas, tais como, Marketing, Vendas, Logística, Produção e Finanças. A previsão de vendas é o elo existente entre as áreas para que possam atingir os objetivos, ao menor custo. Visando mitigar riscos, diante de fatores externos e não controláveis, as empresas buscam reduzir os erros das previsões de vendas.

Um dos objetivos do planejamento é a conciliação entre o fornecimento e demanda por produtos e serviços. De um lado, temos recursos disponíveis aos consumidores e, de outro lado, temos um rol de demandas de consumidores, tanto geral, quanto específicas, o cerne está em conciliar estas duas entidades. (SILVA, 2019)

O conceito de gestão e administração de demanda não é muito difundido, talvez por não ser trivial. Quando pensamos em administrar algo, um processo, por exemplo, normalmente pressupomos que ele esteja, em certa medida, sob controle (CORRÊA *et al.*, 2019). O conceito de demanda está diretamente relacionado a quantidade de bens ou serviços que uma empresa pode comercializar (SILVA, 2020).

O segmento de bebidas não alcoólicas, que inclui a indústria de concentrados, é um setor-chave para a Zona Franca de Manaus (ZFM), com grande impacto socioeconômico especialmente no interior da região. Instalado desde os anos 80 no Polo Industrial de Manaus (PIM), o setor gera mais de dois mil empregos formais e conta com elevados níveis de aquisição de insumos agrícolas locais, sobretudo o guaraná. A média de investimento anual é de US\$ 100 milhões, com faturamento na ordem de US\$ 170 milhões em 2016 responsável por uma movimentação do Imposto sobre Circulação de Mercadorias e Serviços (ICMS) devido de US\$ 7 milhões/ano, conforme dados dos Indicadores de Desempenho do PIM. (CIEAM, 2017)

Em concordância com PEINADO e GRAEML (2007), os processos produtivos não são capazes de fornecer resposta instantânea à demanda, o que implica no fato que as empresas não podem começar a produzir apenas depois do cliente manifestar seu interesse pelo produto (a não ser no caso de vendas sob encomenda). Por isso, a produção precisa ser acionada antes de ter um conhecimento absoluto das quantidades e da variedade de produtos que serão solicitados pelos clientes, o que torna essencial a realização de algum tipo de previsão.

Previsões de vendas preparadas pelo marketing são utilizadas pelo departamento de finanças, para levantar o caixa necessário ao investimento e às operações; pelo departamento de produção, para estabelecer níveis de capacidade de produção; pelo departamento de compras, para aquisição dos suprimentos necessários; e pelo departamento de recursos humanos, para a contratação do número necessário de funcionários. (KOTLER e KELLER, 2012), ou seja, a previsão de vendas é um processo estratégico para as áreas de uma empresa.

O foco do estudo em análise é estabelecer um modelo de previsão de vendas, baseado em dados de uma empresa de bebidas de médio porte situada na cidade de Manaus, ela evoluiu em seus processos nos últimos anos, principalmente no processo produtivo, estabelecendo novas metodologias de análises, projetos e indicadores. Com essa evolução no processo produtivo, outras áreas sentiram necessidade de se adequar, para acompanhar este novo ciclo dentro da empresa.

As áreas Comercial e Marketing se viram diante do desafio de se reestruturar para atender as novas demandas estabelecidas, para início da mudança foi estruturada a área de Inteligência de Mercado, que é responsável em executar as ações para as ajustar e implantar os processos e indicadores da área comercial e de marketing e, principalmente, implantar o processo de previsão de vendas.

SILVA (2020), conceitua que demanda está diretamente relacionada às quantidades de bens ou serviços que o mercado consumidor pretende adquirir em determinado período de tempo. E SILVA (2019), classifica as demandas como dependentes e independentes, onde a primeira é aquela que depende da demanda de outros produtos e/ou serviços e, a segunda, ocorre quando as previsões não são baseadas em previsões de demanda fidedignas.

A escolha do método de previsão de demanda mais adequado parte da disponibilidade dos dados históricos, caso esses dados históricos não existam, ou se forem insuficientes e imprecisos, obrigatoriamente deve ser utilizado um método

qualitativo de previsão. Porém, quando o padrão de demanda não sofre mudanças drásticas ao longo do tempo utiliza-se o método quantitativo de série temporal, mas, se o padrão de demanda sofre maiores variações ao longo do tempo, ou se há um período mais longo de previsão utiliza-se o método quantitativo de regressão linear. (SILVA, 2019)

De acordo com pesquisa realizada pelo ILOS (Instituto de Logística e *Supply Chain*, 2015), 83% das empresas de Bebidas no Brasil utilizam indicadores de assertividade de previsão de vendas, vide Figura 1.1:




Figura 1.1 - Indicadores de assertividade.
Fonte: Pesquisa ILOS (2015).

Para BALLOU (2006), a previsão dos níveis de demanda é vital para a empresa como um todo, à medida que proporciona a entrada básica para o planejamento e controle de todas as áreas funcionais, entre as quais Logística, Marketing, Produção e Finanças. SILVA (2019) avalia que, para minimizar os riscos de uma empresa não atender seus clientes, por falta de estoques de produtos, ou de uma empresa ter suas atividades paralisadas, por falta de insumos, é que devemos fazer previsões de vendas.

Em CHASE *et al.* (2006) entendemos que, em vez de buscar a previsão perfeita, é muito mais importante estabelecer a prática de revisão contínua das previsões e aprender a conviver com essas previsões imprecisas, o que não quer dizer que não é

necessário tentar melhorar o modelo de previsão e a metodologia, mas que se deve tentar encontrar o melhor método de previsão disponível, com bom senso.

É necessário definir estratégias para atender a previsão de demanda e fazer o planejamento agregado da produção e/ou comercialização. O planejamento agregado é imprescindível para que as empresas possam ajustar suas capacidades de produção/vendas com a demanda que, em regra, não é linear e apresenta sempre algum grau de sazonalidade. (SILVA, 2019)

1.2 - OBJETIVOS

1.2.1 - Objetivo geral

Definir um modelo de previsão de vendas a fim de melhorar a tomada de decisão durante o processo de planejamento das atividades de vendas utilizando métodos estatísticos e séries temporais.

1.2.2 - Objetivos específicos

- Levantar os dados necessários para o desenvolvimento do modelo de previsão de vendas, baseado em técnicas estatísticas objetivando o menor erro de previsão.
- Determinar um modelo estatístico de previsão de vendas a ser aplicado ao negócio;
- Estabelecer os indicadores de acurácia do processo a serem utilizados;
- Implementar um processo de previsão de vendas para a empresa baseado no modelo desenvolvido.

1.3 - CONTRIBUIÇÕES DA DISSERTAÇÃO

Em um cenário econômico instável e muito mais competitivo, a utilização de ferramentas como suporte a tomada de decisão para otimizar a participação de uma empresa no mercado perante seus concorrentes é de extrema importância. Contribuindo a esse cenário, a previsão de vendas indica os volumes máximos e mínimos de produção

que uma empresa pode produzir, sem impactar em sua rentabilidade, assim como gera um impacto positivo quando realiza a colaboração entre as áreas da empresa.

Nesse contexto, as empresas iniciam as análises somente baseados em históricos e sensibilidade dos seus administradores, porém, ao longo do tempo foram associando outras variáveis, tais como, preço do produto, ações da concorrência, participação de mercado etc. e, com esse novo pensamento, adquire uma nova postura e começa a realizar planejamentos futuros baseados em ferramentas de previsão de vendas, se utilizando de modelos estatísticos.

Temos como contribuição do estudo a utilização de um processo embasado em metodologias com foco em determinação de dados futuros baseados em modelos estatísticos, matemáticos e econométricos.

Entende-se também que, a criação de etapas definidas para a colaboração das áreas impactadas pela previsão de demanda, contribui como auxílio para análises de comportamentos históricos ou recorrentes, adicionando experiência com situações práticas, onde os resultados esperados a partir do estudo realizado podem auxiliar na gestão do negócio, reunir as áreas envolvidas e/ou impactadas pela previsão de vendas em um único cenário de planejamento.

Outro ponto de contribuição foi a orientação de forma objetiva e prática para a seleção de modelos de previsão, objetivando a implementação de indicadores de acurácia para avaliação dos modelos com menor erro de previsão, além de utilização de ferramentas como Minitab® e Excel®, para a geração dos modelos e consolidação dos dados observados.

Desta forma, espera-se expor que a abordagem do estudo é apropriada para o negócio da empresa que foi utilizada para o estudo.

1.4 - ORGANIZAÇÃO DO TRABALHO

O presente trabalho está exposto em 5 capítulos, organizados conforme a seguir:

O capítulo 1 apresenta a justificativa deste trabalho e quais contribuições o mesmo pode trazer ao negócio em estudo.

No capítulo 2 temos a revisão bibliográfica que suporta as análises a que se dispõe esse estudo, expressando os pensamentos e direcionamentos dos estudiosos que antes deste momento compartilharam os conhecimentos adquiridos.

Na sequência tem-se o capítulo 3 que aborda a metodologia utilizada para o desenvolvimento da pesquisa.

A seguir, o capítulo 4, que exhibe os dados coletados para o estudo que irá viabilizar a análise dos modelos escolhidos além da análise gráfica e embasar o comparativo entre eles.

Fechando o ciclo tem-se o capítulo 5, com as conclusões e considerações finais.

CAPÍTULO 2

REVISÃO DA LITERATURA

2.1 - PREVISÃO DE VENDAS

A processo de previsão de vendas é considerado o principal processo de entrada de dados para o planejamento de áreas na empresa, tais como, produção, compras, comercial, entre outras. Desta forma, sendo a base para uma visão de curto, médio ou longo prazo, norteando as tomadas de decisão, além de organizar os recursos existentes, adquirir recursos adicionais e determinar os recursos desejados.

A projeção de demanda é importante para utilizar as máquinas de maneira adequada, realizar a reposição de materiais no momento e na quantidade certos, e para que todas as demais atividades necessárias ao processo industrial sejam programadas de forma apropriada (MARTINS e LAUGENI, 2015).

CHASE *et al.* (2006) nos conduzem a entender que as previsões são vitais para todas as organizações e para cada decisão administrativa significativa. É a base para o planejamento corporativo a longo prazo. Nas áreas funcionais de finanças e contabilidade, as previsões proporcionam um planejamento orçamentário e controle de custo. O Marketing depende das previsões de vendas para planejar novos produtos, compensar o pessoal de vendas e tomar outras decisões importantes. O pessoal de produção e operações usa as previsões para tomar decisões periódicas envolvendo a seleção do processo, o planejamento de capacidade e o leiaute das instalações, assim como as decisões contínuas sobre o planejamento de produção, a programação e o estoque.

Para muitas empresas, principalmente aquelas multidivisionais, ao menos parte da demanda não vem do ambiente externo, mas de outras divisões ou subsidiárias, o que permite esforços de administração dessas demandas. (CORRÊA *et al.*, 2019)

De acordo com SALAIS-FIERRO *et al.* (2020), a previsão de demanda é uma atividade de planejamento que inclui novas ferramentas analíticas que se somam aos métodos tradicionais conhecidos onde, resumidamente, explica que as técnicas tradicionais combinadas com novas técnicas se tornam cada vez mais importantes nos processos modernos de tomada de decisão.

Vários são os fatores que podem impactar na previsão de vendas, tais como, clima, tempo, taxa de desemprego, novos entrantes de mercado, mudança na rotina de consumo, cronograma de promoções e descontos, novos produtos e/ou embalagens. Mas, um ponto crítico para o sucesso da assertividade da previsão é termos a colaboração das demais áreas impactadas no planejamento.

O processo de previsão sempre será retroalimentado com os resultados alcançados, havendo no histórico as lições aprendidas, os resultados atingidos e as ações realizadas.

O processo de previsão de vendas é possivelmente o mais importante dentro da função de gestão de demanda. Um dos problemas de previsão de vendas é que nunca conseguimos uma previsão 100% correta, ao contrário, na maioria dos casos, não conseguimos nem chegar perto disso. (CORRÊA *et al.*, 2019).

Sendo a previsão de vendas um processo estratégico para o negócio onde está inserido, é importante, além de ter o processo estabelecido, com papéis e responsabilidades, também realizar de forma processual a escolha dos modelos a serem utilizados. E baseado em KRAJEWSKI *et al.* (2012), as previsões são úteis tanto para a administração de processos como para a administração da cadeia de valor.

De muitas formas, a previsão se assemelha ao planejamento administrativo. Previsão é uma maneira analítica de descrever um futuro “*e-se*” com a qual a organização pode confrontar-se (DOANE e SEWARD, 2014).

O que podemos observar, segundo SOREL e GAO (2021), é que o planejamento ou previsão de demanda tem sido amplamente estudado e que os modelos de previsão de demanda podem variar, mas as metodologias básicas permanecem as mesmas.

2.2 - O PROCESSO DE PREVISÃO DE VENDAS

O processo de previsão de vendas é inerente ao negócio onde está inserido, podendo ser estruturado e executado de forma a melhor atender a necessidade do negócio. Vale ressaltar, que o mesmo deve ser estabelecido para mitigar as divergências que podem ocorrer entre a área de produção, vendas e inteligência de mercado e a área de marketing.

No processo de previsão de vendas é importante:

- Organizar as informações;
- Definir o horizonte de planejamento;

- Mensurar os erros;
- Definir o modelo.

Quando se trata da organização das informações é preciso definir o nível de agrupamento da informação, de acordo com o cliente que irá receber, ou seja, podendo ter várias visões para análise e acompanhamento tais como:

1. A abertura do período, que pode ser aberta em mês, semana ou ano, por exemplo;
2. O produto pode ser a nível de *SKU (Stock Keeping Unit)*, portfólio ou grupo de famílias;
3. E o local, pode ser, região, fábrica, estrutura de vendas ou cliente.

Em WOLLACE e STAHL (2003), entende-se que processos recebem entradas, executam conversões e produzem saídas. Logo, fazer previsões acontece da mesma maneira.

Em MARTINS e LAUGENI (2015) tem-se que as previsões, no seu horizonte de planejamento, podem ser de curto, médio e longo prazos.

- Previsões de curto prazo – Até 3 meses
- Previsões de médio prazo – De 2 a 3 anos
- Previsões de longo prazo – Acima de 2 anos.

No curto prazo se tem maior capacidade de previsão e menor erro e no de longo prazo temos menor capacidade de previsão e maior erro.

As empresas de negócio utilizam dados de séries temporais para monitorar se um processo em particular apresenta-se estável ou instável e para auxiliar a predizer o futuro, um processo chamado previsão (DOANE e SEWARD, 2014).

Nas palavras de CORRÊA *et al.* (2019) o sistema de previsão de vendas é o conjunto de procedimentos de coleta, tratamento e análise de informações que visa gerar uma estimativa de vendas futuras, medidas em unidades de produtos (ou família de produtos) em cada unidade de tempo (semana, meses, etc.).

Na Figura 2.1 tem-se uma configuração genérica de um sistema de previsão de vendas, segundo CORRÊA *et al.* (2019).

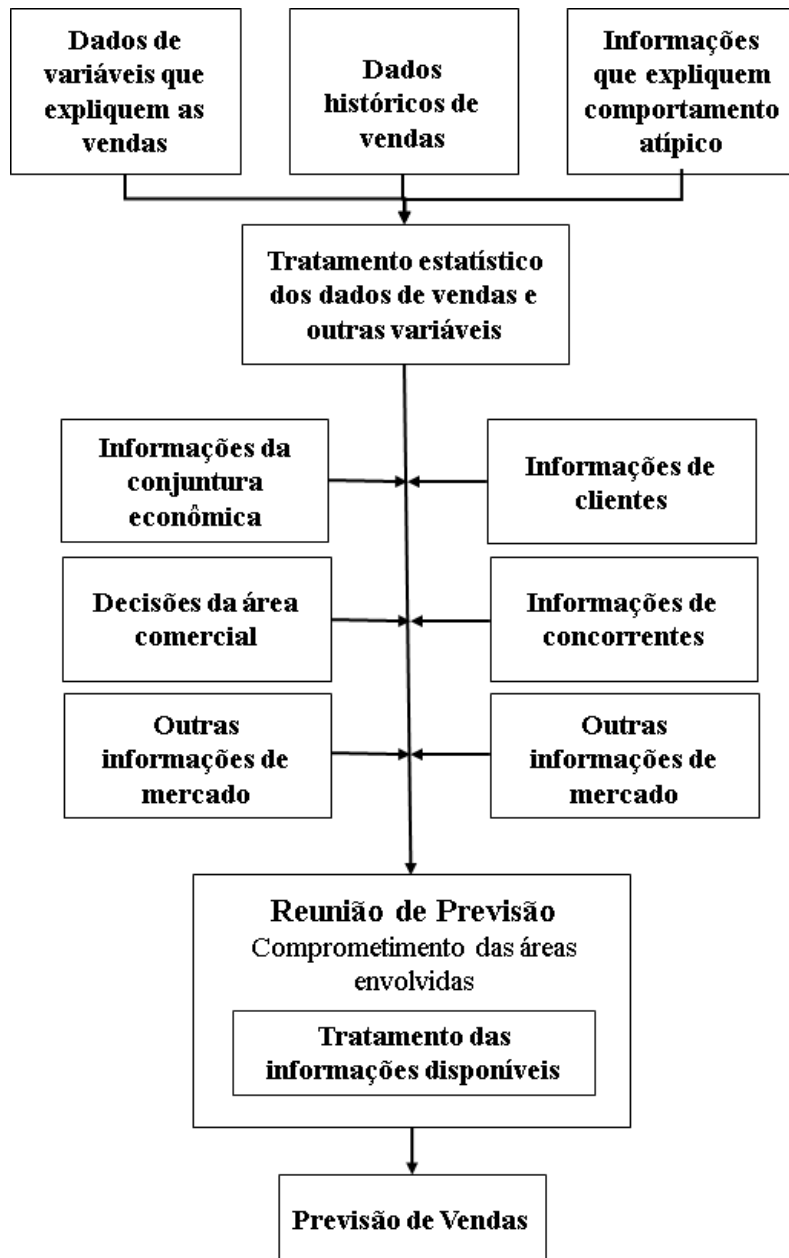


Figura 2.1 - Sistema genérico de previsão de vendas.
 Fonte: Adaptado de CORRÊA *et al.* (2019).

Discorrendo sobre como as empresas podem fazer suas previsões, KOTLER e KELLER (2012), entendem que elas podem desenvolvê-las internamente ou comprá-las de terceiros, como institutos de pesquisas que desenvolvem uma previsão entrevistando clientes, distribuidores e outras partes com conhecimento específico.

As empresas podem preparar até 90 tipos de estimativas de demanda para seis níveis de produtos, cinco níveis espaciais e três níveis temporais (KOTLER e KELLER, 2012), conforme a Figura 2.2 abaixo:

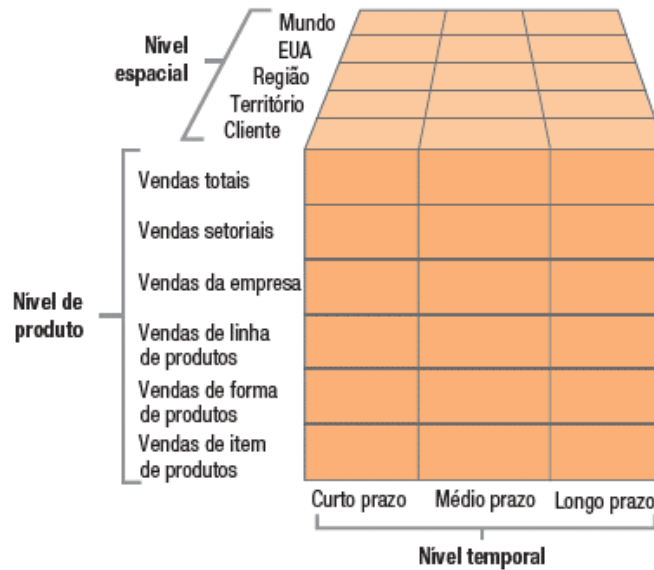


Figura 2.2 - Noventa tipos de estimativa de demanda (6x5x3).
 Fonte: KOTLER e KELLER (2012).

Em WERKEMA (2012) é definido que as são:

1. Definição do objetivo: Que fenômeno será previsto? Qual o grau de exatidão necessária? Quais recursos serão utilizados?
2. Coleta e análise de dados históricos do fenômeno: Quanto mais dados históricos forem coletados e analisados, mais confiável será o modelo de previsão.
3. Construção do modelo de previsão: As técnicas de previsão podem ser qualitativas e quantitativas.
4. Obtenção da previsão: Após a escolha da técnica de previsão e a utilização dos dados históricos para a construção do modelo, é possível efetuar o cálculo das projeções futuras do fenômeno de interesse.
5. Monitoramento do modelo de previsão: O monitoramento do modelo consiste no acompanhamento do desempenho das previsões e na confirmação de sua validade diante de sua atual dinâmica dos dados.

CORRÊA *et al.* (2019) explicita que a função de gestão da demanda inclui esforços em cinco áreas principais, conforme ilustrado pela Figura 2.3: Previsão de demanda, comunicação com o mercado, influência sobre a demanda, promessa de prazos de entrega, além de priorização e alocação.



Figura 2.3 - Processo de gestão de demanda.
 Fonte: CORRÊA *et al.* (2019).

CHASE *et al.* (2006) nos orientam que, previsão perfeita geralmente é impossível, devido a fatores ou ambientes de negócios que não podem ser previstos com certeza. Assim, ao invés de buscar a previsão perfeita é muito mais importante estabelecer a prática de revisão contínua das previsões e aprender a viver com previsões imperfeitas.

2.3 - MÉTODOS UTILIZADOS PARA PREVISÃO DE VENDAS

De acordo com COSTA (2016), as técnicas de previsão podem ser subdivididas em dois grupos, técnicas qualitativas e quantitativas. COSTA (2016) ainda afirma que deve ser considerado o comportamento da demanda para a seleção da técnica de previsão, podendo a demanda ser classificada como: estacional ou média, tendência linear, tendência não linear ou estacional com sazonalidade.

A previsão pode ser classificada em quatro tipos de básicos: qualitativo, de análise de séries temporais, de relacionamento causal e de simulação. (CHASE *et al.*, 2006)

Para PEINADO e GRAEML (2007), existem vários modelos de previsão de demanda, amplamente divulgados na literatura. Há quatro grupos principais de modelos:

- Modelos qualitativos;
- Modelos de decomposição de séries temporais;
- Modelos de previsão causais; e
- Modelos de simulação de demanda.

A escolha do método a ser utilizado para o planejamento de uma previsão de vendas é de extrema importância, pois deve estar adequado ao negócio e ao produto que está sendo analisado. Neste momento o histórico a ser utilizado e as variáveis, que podem vir a influenciar no modelo, contribuem para o resultado alcançado. Os métodos de previsão podem se basear em análises *top-down*, onde observamos os valores agregados ou totais, ou em análises *bottom-up*, onde observamos os valores desagregados ou a um nível mais específico.

Baseado em estudos anteriores, MORETTIN e TOLOI (2018) nos trazem a consciência de que “todos os métodos” de previsão são simplesmente diferentes procedimentos computacionais para calcular a mesma quantidade, a saber, a previsão de mínimos quadrados de um valor futuro a partir de combinações lineares de valores passados. Os procedimentos de previsão utilizados na prática variam muito, podendo ser simples e intuitivos ou mais quantitativos e complexos.

Nas palavras de SLACK *et al.* (2009), há diversas formas de classificar os modelos e técnicas de previsão. Uma classificação divide as técnicas em:

- Subjetivas e objetivas, e
- Não causais e causais.

As técnicas subjetivas são as que envolvem julgamento e intuição, as técnicas objetivas são as que possuem procedimentos especificados e sistemáticos. As técnicas não causais são as que usam valores passados de uma variável para prever valores futuros e as técnicas causais procuram fazer previsões com base em uma relação causal.

Na Figura 2.4 temos os tipos de técnicas estatísticas e suas divisões.

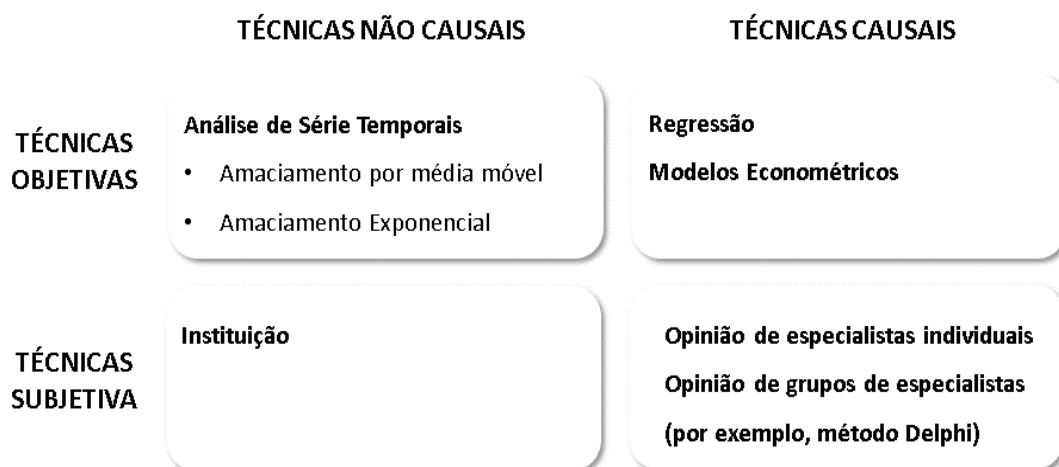


Figura 2.4 - Técnicas estatísticas
 Fonte: Adaptado de DOANE e SEWARD (2014).

Em WERKEMA (2012), as previsões podem ser qualitativas ou quantitativas. As técnicas qualitativas como são mais rápidas de se preparar, são empregadas quando não se dispõe de tempo para coletar e analisar dados históricos sobre o fenômeno. As técnicas quantitativas empregam modelos matemáticos, com base em dados históricos, para projetar o comportamento futuro do fenômeno.

Os métodos qualitativos incluem métodos de avaliação qualitativos, que convertem as opiniões de gerentes e especialistas, pesquisas ao consumidor e estimativas de força de vendas em estimativas quantitativas. (KRAJEWSKI *et al.*, 2012). Os métodos quantitativos, como o próprio nome diz, utilizam uma série de dados numéricos – que mostram variações de demanda em períodos passados – para projetar e estimar seus valores no futuro. (SILVA, 2020)

2.3.1 - Métodos qualitativos

PEINADO e GRAEML (2007) pontuam que modelos qualitativos são apropriados quando não existem dados históricos a serem analisados como base de previsão, na maioria dos casos dependem de especialistas com experiência de mercado. Os principais métodos são:

- **Predição:** Processo baseado em dados subjetivos, de natureza duvidosa. É uma aposta no futuro, com grande risco e sujeito a sorte, em muitos casos, interpretado como visão ou feeling.
- **Opiniões dos Executivos:** Previsões baseadas em um pequeno grupo de executivos de, geralmente ligados à área comercial, financeira e de produção. Neste núcleo a previsão pode não ser o consenso do grupo, mas a opinião de quem detém o maior nível hierárquico, experiência ou força de persuasão.
- **Método Delphi:** é um processo de colaboração sigilosa, os dados são coletados por meio de questionário, por *e-mail* ou forma similar, sem que um integrante saiba a opinião do outro. Um coordenador recebe e consolida os dados, gera o primeiro resultado e reenvia ao mesmo grupo para que possam reavaliar sua opinião, se considerarem adequado, em função dos argumentos dos demais que são apresentados de forma agregada. Vale salientar que os membros desse grupo precisam ter confiança no processo para dar o parecer de forma legítima. Para BALLOU (2006), essa técnica elimina o efeito cascata da opinião da maioria.

- **Opiniões da equipe de vendas:** Consiste em solicitar diretamente a equipe de vendas que forneça a estimativa por cada região de atuação, esta estimativa é agregada a uma base que passa a representar a previsão global de vendas. Para contribuir com o tópico temos a citação de KRAJEWSKI *et al.* (2012), onde fala que uma das vantagens da opinião da força de vendas a de que é de um grupo que muito provavelmente sabe quais serviços ou produtos ou clientes comprarão no futuro próximo e em que quantidades.
- **Pesquisa de mercado:** é de extrema importância quando há um novo lançamento de produto, embalagem ou tamanho, também se aplica quando há um novo player no mercado de atuação. Uma pesquisa é qualquer investigação organizada executada para se obter informações para soluções de problemas.
- **Analogia com produtos similares:** é quando, em um lançamento de um novo produto, se faz associação com produtos similares.

A natureza não científica desses métodos torna difícil sua padronização ou mesmo a validação de sua exatidão. Há, porém, ocasiões em que esses métodos são todo o arsenal de que se dispõe para prever o sucesso de novos produtos, mudanças de políticas de governo, ou o impacto de uma nova tecnologia. (BALLOU, 2006)

SILVA (2020), cita como método qualitativo, além dos informados acima:

- **Intenção do comprador:** a verificação das intenções de compra do público-alvo por meio de pesquisas de mercado é também um método muito útil que pode ser empregado quando não há informação histórica sobre a demanda de um produto ou serviço.

2.3.2 - Métodos quantitativos

Os métodos quantitativos incluem métodos causais e análise de séries temporais. Os métodos causais usam dados históricos sobre variáveis independentes, como campanhas promocionais, condições econômicas e ações dos concorrentes para prever a demanda. A análise de séries temporais é uma abordagem estatística que conta muito com dados históricos sobre a demanda para projetar o tamanho futuro da demanda e reconhecer tendências e padrões sazonais. (KRAJEWSKI *et al.* 2012)

A natureza quantitativa das séries de tempo incentiva o uso de modelos matemáticos e estatísticos como principais fontes de previsão. Esses modelos

funcionam bem simplesmente devido à estabilidade inerente às séries de tempo no curto prazo. (BALLOU, 2006)

A Tabela 2.1 exibe modelos quantitativos e o horizonte de tempo de previsão que cada um aplica em sua análise.

Tabela 2.1 - Métodos estatísticos e horizontes.

Método Quantitativos	Horizonte do tempo de previsão
Média Móvel	Curto
Ponderação Exponencial	Curto
Box Jenkins	Curto - Médio
Decomposição de Séries de Tempo	Curto - Médio
Projeções de Tendência	Curto - Médio
Regressão	Curto - Médio

Fonte: Adaptado de BALLOU (2006).

De acordo com DOANE e SEWARD (2014), a Figura 2.5 resume as principais categorias de modelos de previsão:

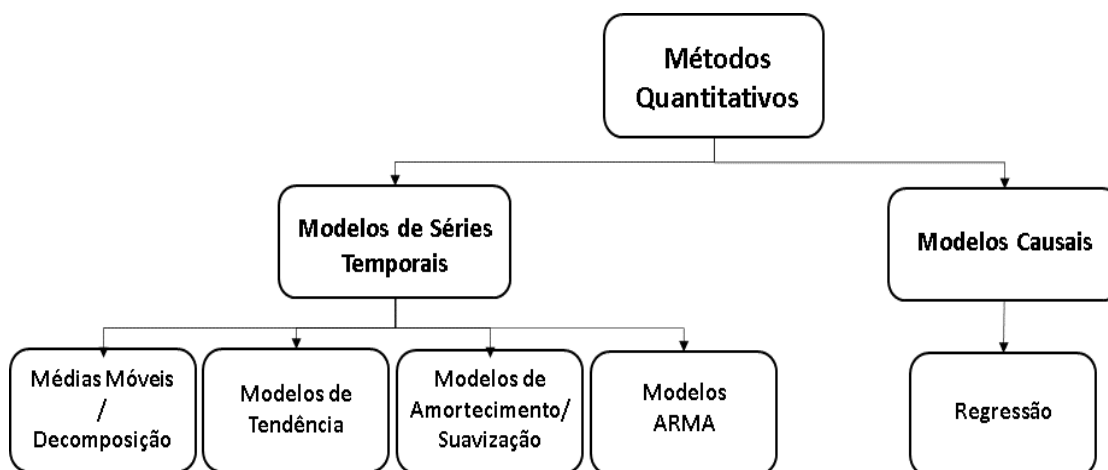


Figura 2.5 - Principais categorias de modelo de previsão.

Fonte: DOANE e SEWARD (2014).

WERKEMA (2012) lista que as características para uma técnica quantitativa são:

1. Utilizam a análise numérica de dados passados e não envolvem opiniões pessoais;

2. Empregam modelos matemáticos com base em dados históricos, para projetar o comportamento futuro do fenômeno.
3. Podem ser divididos em dois grupos:
 - a. Técnicas baseadas em séries temporais, que modelam matematicamente o comportamento futuro do fenômeno relacionando os dados históricos do próprio fenômeno com o tempo.
 - b. Técnicas baseadas em correlação, que associam os dados históricos do fenômeno a uma ou mais variáveis que tenham alguma relação com o mesmo.

Além dos métodos citados anteriormente, em BAZIONIS e GEORGILAKIS (2021) cita os métodos determinísticos e probabilísticos, que foram pesquisados nas últimas décadas e que cada um tem suas próprias vantagens ao ser usado, portanto é importante considerar essas vantagens dependendo da área que está sendo pesquisado.

A vantagem de um método determinístico é sua simplicidade, eles não apenas são mais rápidos de usar e reproduzir, mas também são muito mais fáceis de compreender e avaliar. E a vantagem de um modelo probabilístico é a estimativa da incerteza dos valores previstos, estes modelos oferecem um intervalo onde são dados vários valores possíveis para um tempo específico e como resultado, oferecem uma visão mais ampla dos possíveis resultados do modelo pesquisado. (BAZIONIS e GEORGILAKIS, 2021)

2.3.2.1 - Modelos de séries temporais

CHASE *et al.* (2006) explica que os modelos de séries temporais são baseados na ideia de que a história de ocorrências com o tempo pode ser usada para prever o futuro, tais como:

1. Média Móvel Simples: Pondera-se um período de tempo contendo um número dividindo a soma dos valores dos pontos pelo número de pontos. Cada um deles portanto tem influência igual.
2. Média móvel ponderada: Pontos específicos podem ser ponderados mais ou menos do que os outros, como parecerem adequados pela experiência.
3. Média ponderada exponencial: Pontos recentes são ponderados mais com o peso, que declina exponencialmente à medida que os dados se tornam mais antigos.

4. Técnica de Box Jenkins: Muito complicada, mas aparentemente a técnica estatística mais precisa disponível. Relaciona uma classe de modelos estatísticos aos dados e adapta o modelo a série temporal usando as distribuições posteriores de *Bayesianas*.

Os modelos de média móvel são adequados quando se adota hipóteses de permanência, isto é, sem que se identifique tendência de aumento de ou decréscimo acentuado nas vendas no futuro. (CORREA *et al.*, 2001)

A média móvel simples (MMS) é calculada conforme a Eq. (2.1):

$$P_t = \frac{V_{t-1} + V_{t-2} + \dots + V_{t-N}}{N} \quad (2.1)$$

Onde:

P = Previsão de vendas para o próximo período;

t = período do tempo;

N = Número de observações;

V = Valor das variáveis observadas no tempo t.

Na média móvel ponderada se atribui um peso a cada um dos dados, sendo que a soma dos pesos deve ser igual a 1 (MARTINS e LAUGENI, 2015).

A média móvel ponderada (MMP) é calculada conforme a Eq. (2.2):

$$P_t = \frac{V_{t-1} \times a + V_{t-2} \times b + \dots + V_{t-N} \times n}{a + b + \dots + n} \quad (2.2)$$

Onde:

P = Previsão de vendas para o próximo período;

a, b, ..., n = fatores de ponderação;

t = período de tempo;

V = Valor das variáveis observadas no tempo t.

No amortecimento exponencial simples temos a destinação de séries que não possuem tendência sendo necessário que a série observada seja estável, como é um método de fácil aplicação, não exige uma série histórica longa e há uma ponderação nos dados observados, a mesma é calculada pela Eq. (2.3):

$$P_j = \alpha \bar{D} + (1 - \alpha)D_{j-1} \quad ()$$

Onde:

P_j = Previsão para um período j ;

\bar{D} = demanda média dos últimos períodos;

α = Constante de suavização ($0 \leq \alpha \leq 1$);

D_{j-1} = Demanda real ocorrida no período anterior ao período j .

CHASE *et al.* (2006), explica os motivos para que as médias ponderadas exponenciais, ou amortecimento exponencial, tornaram-se bem aceitas:

1. Os modelos exponenciais são surpreendentemente precisos;
2. A formulação de um modelo exponencial é relativamente fácil;
3. O usuário consegue entender como o modelo funciona;
4. É preciso pouca computação para usar o modelo;
5. As necessidades de armazenamento em computadores são pequenas por causa do uso limitado de dados históricos;
6. Os testes de precisão, para saber quão bem o modelo está se saindo, são fáceis de implementar.

Em ALVES *et al.* (2019) a definição de suavização exponencial dupla define que, este método, é em geral uma ferramenta eficaz de previsão para dados de série temporal que exibem uma tendência linear que é expressa pela Eq. (2.4):

$$\hat{Y}_{t+n} = E_t + nT_t \quad (2.4)$$

Onde:

A previsão para o período de tempo $t+n$ (\hat{Y}_{t+n}) é igual a estimativa do nível esperado da série temporal no período de tempo t (Y_t) mais a influência esperada da tendência (taxa de aumento ou redução) durante os próximos n períodos (nT).

Em MORETTIN e TOLOI (2018) temos que, quando o método de suavização exponencial simples (SES) é aplicado a uma série que apresenta tendência linear positiva (ou negativa) fornece previsões que subestimam (ou superestimam) continuamente os valores reais. Por este motivo, MORETTIN e TOLOI (2018) explica que, para evitar o erro sistemático da suavização exponencial simples, se faz necessário

usar o método de suavização exponencial de *holt* (SEH), também conhecido como método de suavização exponencial dupla, esse método é similar ao método SES), a diferença é que ao invés de suavizar só o nível ele utiliza uma nova constante de suavização para “modelar” a tendência da série.

Modelos que buscam incorporar o componente de tendência à previsão de demanda são conhecidos como métodos ajustados à tendência e, em linha gerais, são modelos que utilizam uma dupla suavização, ou um amortecimento, ou seja, empregam duas equações de ajustes com fatores de suavização, uma para a média de valores históricos de demanda e outra para uma série de valores de tendência. (SILVA, 2020)

Os modelos de séries temporais envolvem a análise do comportamento do passado para projetar o futuro, obviamente, são aplicados em produtos que possuem um histórico estável de demanda e onde as variações ao longo do tempo não são significativas. Para estes modelos utiliza-se uma série histórica de 12 a 24 meses, desta forma é possível avaliar ciclo, tendência e sazonalidade do produto.

SILVA (2019) explica que uma série temporal de demandas passadas pode ser analisada por suas principais características (atributos):

- NÍVEL: Volume de vendas passadas, desconsiderando variações decorrentes da sazonalidade e aleatoriedade.
- TENDÊNCIA: Podem apresentar tendência crescente (alta demanda), estabilizada (sem alterações em longos períodos) e decrescente (redução de demanda)
- SAZONALIDADE: Padrão de variação de demanda ao longo do tempo que pode ser previsto.

Na Figura 2.6 podemos observar que as tendências observadas no passado devem permanecer no futuro, assim como a ciclicidade observadas no passado.




Figura 2.6 - Projetando as vendas futuras com base em dados do passado.
 Fonte: CORRÊA *et al.* (2019).

Além dos componentes característicos acima, WERKEMA (2012) inclui também o de ciclicidade, que são os altos e baixos em torno da qual as observações da série temporal se distribuem ao longo de período superior a um ano.

Na Figura 2.7 demonstra-se graficamente os padrões de demanda, onde os dados são distribuídos no tempo de análise e na maioria são de séries temporais.

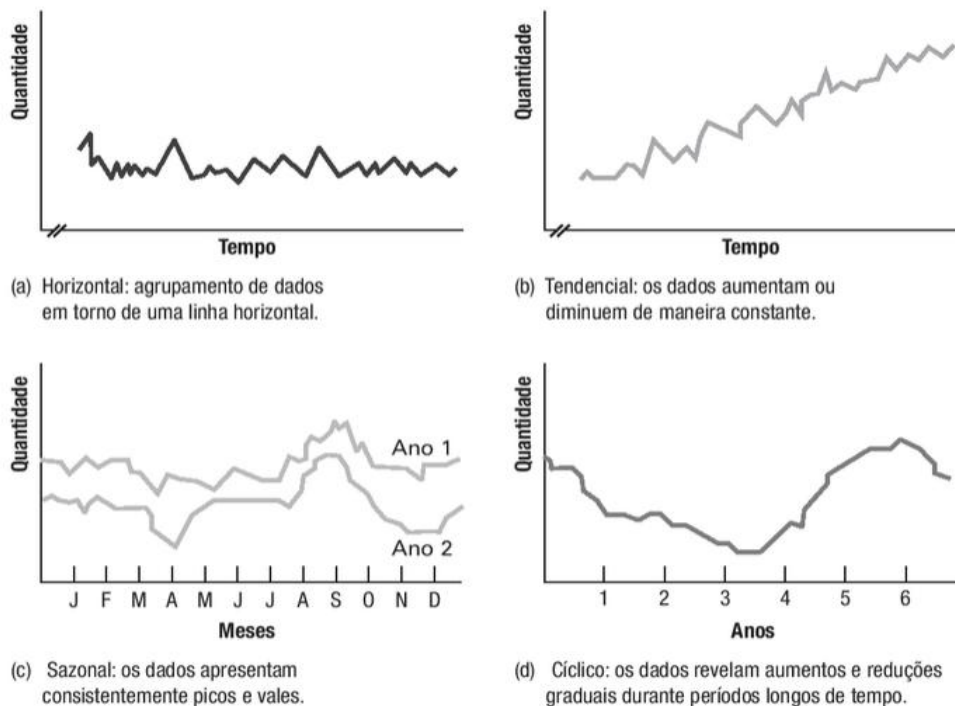


Figura 2.7 - Padrões de demanda.
 Fonte: KRAJEWSKI *et al.* (2012).

Modelos de série de tempo são reativos por natureza. São modelos que detectam mudanças a partir da atualização sempre que novos dados se tornam disponíveis, uma característica que lhes permite adaptar-se a mudanças nos padrões de tendências e sazonais. (BALLOU, 2006)

2.3.2.2 - Modelo causal

Outro tipo a ser utilizado é o modelo causal, que de acordo com CHASE *et al.* (2006), é um modelo que tenta entender o sistema básico e ao redor do item que está sendo previsto.

Os métodos causais são usados quando dados históricos estão disponíveis, e a relação entre os fatores a serem previstos e outros fatores — externos ou internos — (como, ações governamentais ou promoções publicitárias) — pode ser identificada. Essas relações são expressas em termos matemáticos e podem ser complexas. Os métodos causais fornecem as ferramentas de previsão mais sofisticadas e são úteis para prever pontos de inflexão na demanda e para preparar previsões de longo alcance. (KRAJEWSKI *et al.* 2012)

O principal modelo causal é o de Regressão, que é similar aos métodos dos mínimos quadrados, podendo conter variáveis múltiplas.

WERKEMA (2012) explica que a análise de regressão é uma técnica estatística usada para investigar e modelar o relacionamento entre duas ou mais variáveis. Sua utilização vem se ampliando a cada dia, principalmente ao fato de essa ferramenta ser baseada na ideia relativamente simples de se empregar uma equação para expressar o relacionamento entre as variáveis de interesse.

O modelo de previsão de demanda dos mínimos quadrados é um pouco mais elaborado, podendo ser aplicado a séries temporais de demandas que apresentam tendência, mas não apresentam sazonalidade. Demandas desta natureza podem ser representadas, por exemplo, por produtos que se encontram na fase de crescimento (tendência crescente) ou em fase de declínio (tendência decrescente), dentro do seu ciclo de vida (PEINADO e GRAEML, 2004).

O método da regressão linear (ajustamento de retas) consiste em determinar a função $Y = a + bX$, sendo Y a variável dependente e X a variável independente. Para a execução dos cálculos com as calculadoras, utilizamos a expressão a seguir, que facilita os cálculos (MARTINS e LAUGENI, 2015).

Para o cálculo da equação da reta utilizamos a Eq. (2.5):

$$Y = a + bx \quad (2.5)$$

DOANE e SEWARD (2014) expõem que a série de tendência linear é útil para uma série que cresce e decresce por uma mesma quantidade em cada período. É o modelo mais simples e deve ser suficiente para uma previsão de curto prazo.

2.3.3 - Erros de previsão

Nenhum erro de previsão terá sucesso se os erros não forem apontados e analisados com o objetivo de reavaliar as hipóteses, modificar o método de previsão e ganhar o comprometimento com a melhoria do processo (CORRÊA *et al.*, 2019).

Um bom modelo de previsão capta o comportamento sistemático da demanda e indica o comportamento aleatório pela amplitude do erro, conforme PEINADO e GRAEML (2007), onde este erro que faz parte do resultado de previsão é fundamental por duas razões:

Os erros demonstram o quanto o modelo de previsão utilizado é adequado: à medida que as demandas reais vão sendo obtidas se mantiverem compatíveis com as estimativas históricas, tem-se um indicativo de que o modelo de previsão adotado continua válido;

Os erros de previsão são importantes para o planejamento logístico: Quanto maior a variação aleatória da previsão de demanda, maior deverá ser o estoque de segurança para manter o mesmo nível de serviço no atendimento ao cliente.

Para escolher um modelo de previsão, MARTINS e LAUGENI (2015), podemos escolher utilizando diferentes métodos, tais como:

- a) Soma Acumulada dos Erros de Previsão (SAE);
- b) Erro Quadrado Médio (EQM);
- c) Desvio Padrão (DP);
- d) Média da Soma dos Erros Absolutos (MSEA).

KRAJEWSKI *et al.* (2012) explicam que, as previsões quase sempre contêm erros, estes podem ser classificados como erros sistemáticos ou erros aleatórios. Os sistemáticos são o resultado de equívocos constantes — a previsão é sempre muito alta

ou muito baixa. O erro aleatório, resulta de fatores imprevisíveis que fazem com que a previsão se desvie da demanda real.

Em BALLOU (2006) o erro de previsão é definido como:

$$\text{Erro de previsão} = \text{demanda real} - \text{demanda prevista}$$

Porém, sendo a demanda prevista um valor aritmético médio, a soma dos erros de previsão ao longo de um determinado número de períodos deveria ser igual a zero.

A CFE (*Cumulative Sum of Forecast Errors* — soma cumulativa de erros de previsão) mede o erro de previsão total é dada pela Eq. (2.6):

$$CFE = \sum E_t \quad (2.6)$$

Os erros positivos grandes tendem a ser compensados por erros negativos grandes na medida CFE. Contudo, ela é útil ao avaliar desvios em uma previsão.

O MSE (*Mean Squared Error* — erro médio ao quadrado), o desvio-padrão (δ) e o MAD (*Mean Absolute Deviation* — desvio absoluto médio) medem a dispersão dos erros de previsão:

$$MSE = \frac{\sum E_t^2}{n} \quad (2.7)$$

$$\delta = \sqrt{\frac{\sum (E_t - \bar{E})^2}{n - 1}} \quad (2.8)$$

$$MAD = \frac{\sum |E_t|}{n} \quad (2.9)$$

Se MSE, δ ou MAD são pequenos, a previsão geralmente está próxima da demanda real; por outro lado, um valor grande indica a possibilidade de grandes erros de previsão.

O MAPE (*Mean Absolute Percent Error* — erro percentual absoluto médio) relaciona o erro de previsão ao nível de demanda e é útil para colocar o desempenho de previsão na perspectiva adequada:

$$MAPE = \frac{\sum |E_t|}{n} \times 100, \text{ expresso em percentual} \quad (2.10)$$

O MAPE é a melhor medida de erro a ser utilizada quando são feitas comparações entre séries temporais para diferentes *SKUs*.

2.3.4 - Controle do modelo de previsão

Para que se possa acompanhar o modelo selecionado e verificar se ainda representa os dados observados, MARTINS e LAUGENI (2015) apresentam duas variáveis que permitem esse acompanhamento que são: *Tracking Signal* – TS e *Trigg Signal* – TR.

O sinal de rastreamento (TS), calculado conforme a Eq. (2.11), é uma variável normal de média zero e desvio padrão 1 e aceita-se que o modelo de previsão utilizado continua válido sempre que o sinal de rastreamento esteja compreendido entre -3 e +3.

$$\text{Sinal de rastreamento} = TS = \frac{\sum E_t}{\frac{\sum |E_t|}{n}} \quad (2.11)$$

O sinal de *trigg* (TR), conforme a Eq. (2.12), procura corrigir a distorção que existe em TS e é calculado conforme a equação a seguir:

$$TR = \frac{\text{Erro médio exponencial}}{\text{Desvio absoluto acumulado médio}} = \frac{EME}{DAAM} \quad (2.12)$$

Sendo EME calculado conforme a Eq. (2.13):

$$EME_t = (\text{Desvio médio}) + (1-\alpha)(EME_{t-1}) \text{ com } 0 < \alpha < 1 \quad (2.13)$$

2.4 - ANÁLISE DE RESÍDUOS

Conforme WERKEMA (2012) um resíduo é definido por:

$$e_i = y_i - \hat{y}_i, i = 1, 2, 3, \dots, n \quad (2.14)$$

Onde:

y_i é uma observação;

\hat{y}_i é o valor correspondente calculado por meio da reta de regressão.

Em outras palavras:

$$\text{Resíduo} = \text{valor observado} - \text{valor predito} \quad (2.15)$$

Por análise gráfica os resíduos têm padrões similares a Figura 2.8 onde, no item (a) a técnica de previsão utilizada é adequada e os erros são distribuídos aleatoriamente ao longo do tempo. Por outro lado, conforme nos itens (b), (c) e (d), da Figura 2.8 se a técnica de previsão não for adequada, os resíduos podem apresentar uma configuração sistemática na qual fica evidente, por exemplo, que se deixou de levar em consideração uma tendência (b), uma variação cíclica (c) ou variações sazonais (d).

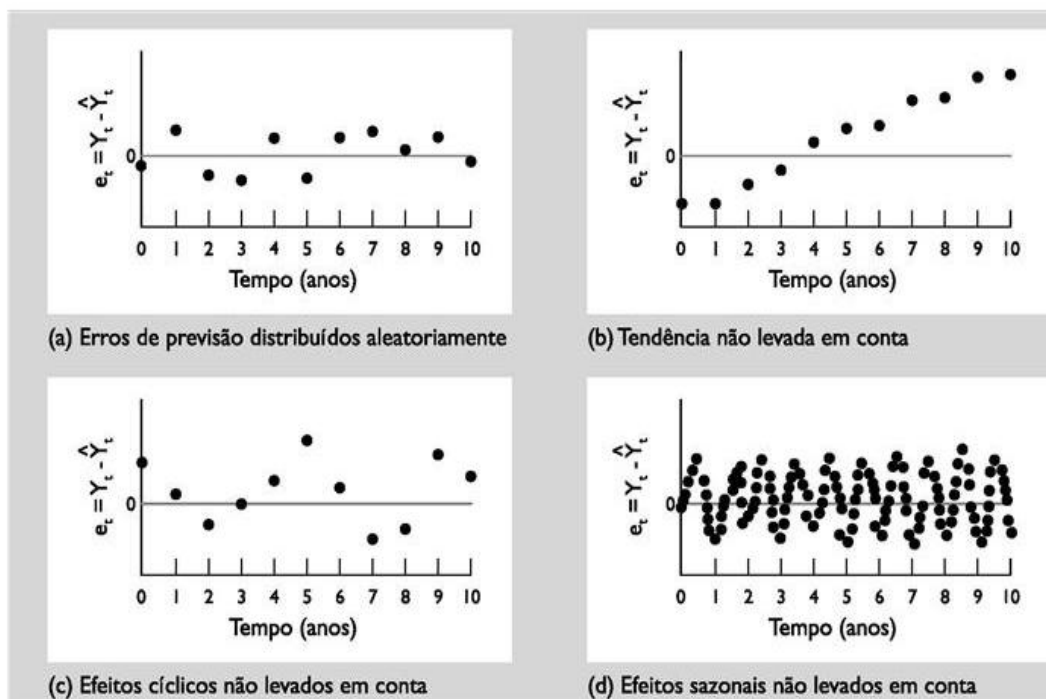


Figura 2.8 - Gráfico sequencial para estudo da configuração dos erros individuais de previsão.

Fonte: WERKEMA (2012).

2.5 - APLICAÇÕES

FRAGOSO (2009), ao propor um processo formal e sistemático de demanda de venda, esclarece que o passado, diversos softwares foram desenvolvidos com o objetivo de proporcionar previsões estatísticas confiáveis através da simulação de diversas formas de previsão para os dados históricos, cálculo dos erros acumulados, e opção de previsão utilizando o método que melhor se comportou nos últimos meses. Esta

sistemática, hoje em dia, é bastante simples de ser usada devido às variadas opções de softwares existentes, além de soluções caseiras que possam ser criadas.

Contribuindo com o exposto, SANTOS e NETO (2018), em um estudo de caso em uma indústria de equipamentos para piscinas e spas analisa a relevância da análise e previsão de demanda como ferramenta a auxiliar na reposição de itens de demanda dependente utilizando método de previsão de abordagem quantitativa, ou seja, baseado em séries históricas, definindo e aplicando o modelo adotado, e comparando resultados da previsão com o realizado.

As previsões podem ser qualitativas e quantitativas, baseado em um estudo com dados de vendas de materiais eletromecânicos, ZAN (2007) dispõe que as previsões qualitativas são de julgamento de especialistas ou de pessoas que possam, por experiência ou conhecimento adquirido, antever eventos de interesse ou correlacionar circunstâncias, de modo que possa gerar uma previsão das vendas em período futuro, e as quantitativas se valem de modelos matemáticos e incluem o método causal e a análise de série temporal.

Em um estudo de previsão de demanda para uma empresa de equipamentos agrícolas, BLOCK *et al.* (2017) realiza um comparativo entre o método qualitativo Delphi, utilizado pela empresa do estudo, e o método quantitativo sazonalidade simples, escolhido pelo autor do estudo, onde, através do erro absoluto médio, temos que o método quantitativo apresenta menor erro de previsão, conforme Tabela 2.2.

Tabela 2.2 - Análise de erros obtidos pelos métodos de previsão de demanda.

MÉTODO	ERRO ACUMULADO	MAD
DELPHI (EMPRESA)	-126	-31,5
SAZONALIDADE (AUTOR)	-23	-5,75

Fonte: BLOCK *et al.* (2017).

Em uma proposta de modelo de previsão de vendas para um jornal, JÚNIOR (2016), propôs uma metodologia que permita utilizar técnicas de previsão de demanda no apoio a tomada de decisão, utilizando o monitoramento dos erros de previsão, porém, afirmando que este monitoramento não deve restringir o cálculo de acurácia, onde para este estudo foram utilizados os cálculos de acurácia utilizando o MAD, o

MPE e o MAPE para os métodos de previsão média móvel simples, média móvel dupla e média ponderada.

BATISTA (2017), afirma que para uma melhor análise dos modelos utilizam-se medidas de acurácia com o objetivo de avaliar e, por consequência, escolher o método mais adequado para realizar as previsões, onde MAPE (*Mean absolute Percentage Error*) e RMSE (*Root Mean Square Error*) foram as medidas escolhidas para serem utilizadas para análise de previsão de vendas no varejo de vestuário. JÚNIOR *et al.* (2018) ratificam o uso do MAPE por ser o mais utilizado dentre as medidas relativas, pelo fato de ser bem interpretativo e bastante apropriado no planejamento.

Na Figura 2.9 tem-se a proposta de LEMOS (2006) de metodologia para seleção de método de previsão de vendas, com etapas e fatores de decisão pré-definidos, que são: (i) Definição do problema; (ii) Obtenção de dados; (iii) Escolha do(s) método(s) de previsão; (iv) Seleção do pacote computacional; (v) Implementação do(s) método(s); e (vi) Validação do(s) método(s).

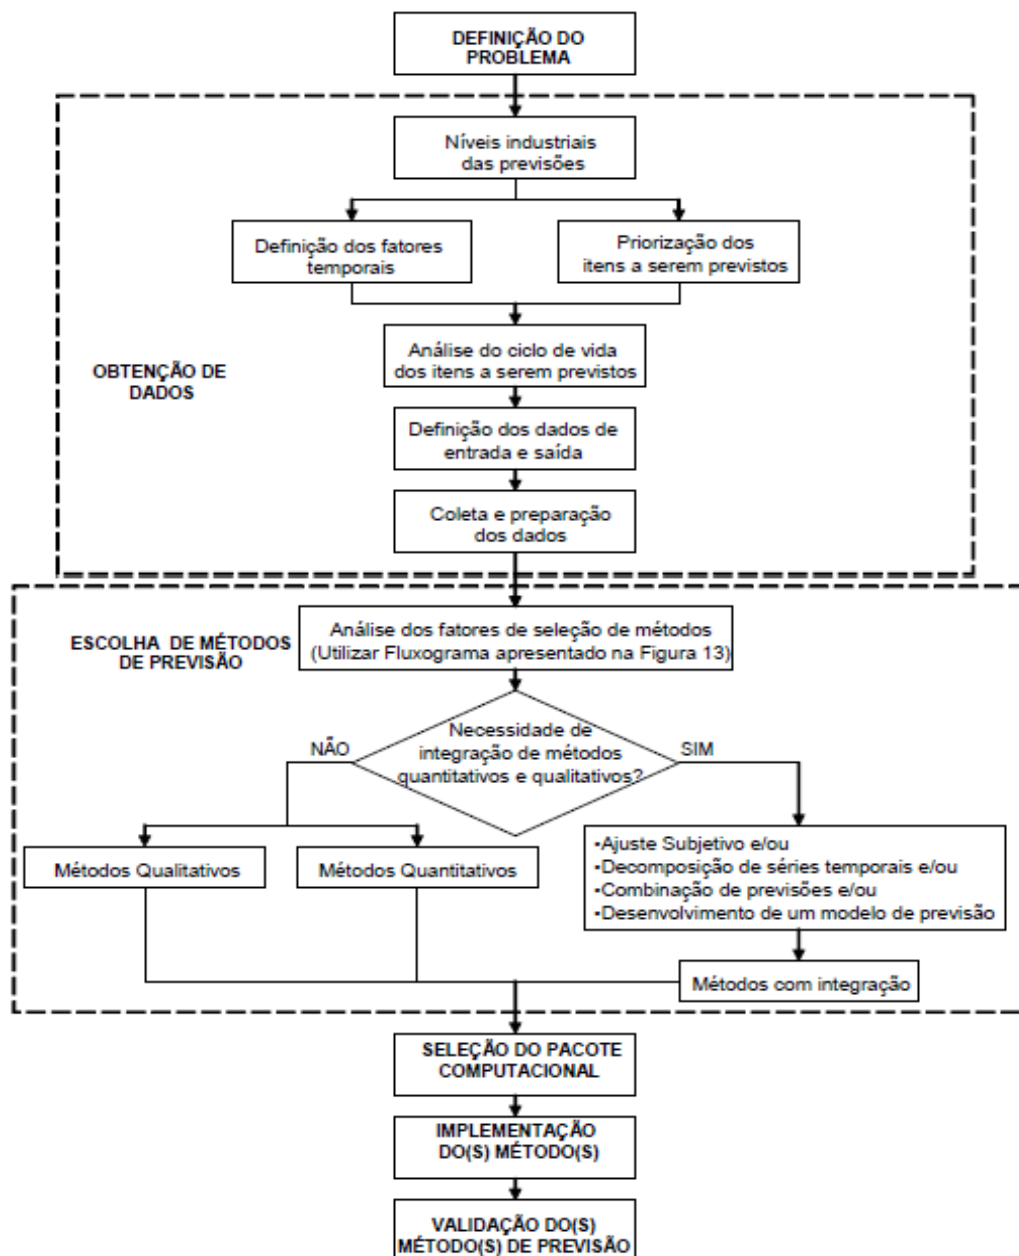


Figura 2.9 - Metodologia proposta para seleção de métodos de previsão de demanda.
Fonte: LEMOS (2006).

Fundamentado em uma pesquisa explicativa, embasada em estudos descritivos e exploratórios, para uma empresa distribuidora de rolamentos, MANCUZO (2003), conclui que a análise de previsão de demanda deverá ser uma ferramenta imprescindível na administração de estoque e nas compras da empresa, trazendo para a empresa vantagem competitiva pela aproximação com os clientes por meio do atendimento das suas demandas variáveis ofertando o produto que o mercado necessita, além de reduzir as incertezas na entrega com fornecedores bem como redução em despesas extras para atendimento de compras urgentes.

GUERRA (2019), no estudo de caso para escolha de métodos de previsão da demanda de uma empresa de alimentos, comparou sete métodos para planejamento de demanda aplicando os modelos de suavização exponencial com e sem sazonalidade e usou como medida de acurácia o indicador MAPE. Após a realização da pesquisa, verificou-se que, por causa do padrão de demanda dos itens comercializados pela empresa, é improvável que os modelos sugeridos pela literatura contribuam de forma eficaz para um planejamento de demanda eficaz.

A fim de encontrar um método de previsão que forneça maior acurácia para produtos com demanda aleatória, SANTOS (2017), utilizou dois métodos para confrontar o método oficial da empresa em estudo: o método de Croston e o método de previsão de média simples dos últimos 6 meses de vendas. A escolha do melhor método de previsão, foi realizado através da análise dos erros. Para tal, foi utilizado o erro médio absoluto (EMA) como critério de escolha pois através dele, os métodos podem ser facilmente confrontados.

Em uma avaliação de modelos de previsão de vendas a partir da exploração de técnicas de análises de séries temporais, métodos causais e de redes neurais artificiais, REIS (2014), desenvolveu alternativas de modelos de previsão ao estudar a série de vendas de uma indústria têxtil brasileira. A alternativa com melhor acurácia foi eleita para ser testada e comparada com os demais métodos, onde o indicador de acurácia utilizado para o estudo foi o MAPE (Médias dos erros percentuais absolutos). Este estudo corroborou com recentes pesquisas que apontam que modelos de previsão de vendas com combinação de técnicas geram melhores previsões.

Com o objetivo desenvolver um modelo de previsão de vendas para uma indústria têxtil, por meio da aplicação de métodos de previsão de séries temporais, BRUNATO *et al.* (2016), buscou evidenciar que por meio da aplicação de métodos estatísticos de previsão de séries temporais que a indústria analisada seria capaz de realizar previsões mais acuradas. Após análises, um modelo de Suavização Exponencial de Holt-Winters com erro aditivo, sem tendência, e com sazonalidade aditiva foi selecionado, porém, a metodologia Box-Jenkins apontou diversos modelos como adequados.

Em um estudo de caso de uma empresa do setor têxtil, GIRRDI (2008), comparou o planejamento de vendas realizado pela empresa e métodos quantitativos de previsão de vendas, onde o primeiro apresentou a pior acurácia de todos os métodos realizados, conforme observado na Tabela 2.3.

Tabela 2.3 - Comparação da acurácia entre os modelos de previsão de vendas para os produtos analisados.

MAPE (%)	Modelo Box & Jenkins com intervenção	Método Combinado	Método Integrado	Previsão da Empresa
PRODUTO A	14,25	13,27	12,75	53,23
PRODUTO C	12,38	9,37	7,32	12,6
PRODUTO D	16,61	16,94	18,26	67,29
PRODUTO E	42,75	44,38	41,5	128,49
PRODUTO H	11,4	12,00	11,52	35,68
PRODUTO M	13,61	12,24	13,81	21,96

Como destacado no estudo Método estruturado para o processo de planejamento da demanda nas organizações, MIRANDA *et al.* (2019), conclui que o processo de previsão ainda apresenta consideráveis deficiências, problemas que ocorrem devido a uma gama maior de fatores, tais como: identificar quais são as áreas funcionais da empresa que participam do processo de previsão e suas relações, conhecimento de métodos de previsão, existência de software de previsão, utilização de métodos quantitativos e medição do impacto que o erro de previsão tem na performance das diversas áreas da empresa.

CAPÍTULO 3

MATERIAIS E MÉTODOS

Este capítulo tem uma visão clarificada das etapas, metodologias e técnicas aplicadas para análise dos dados utilizados.

Essa pesquisa está sendo desenvolvida em uma empresa de bebidas situada na cidade de Manaus, contendo em seu portfólio mais de 50 *SKUs* (*Stock Keeping Unit*) de fabricação própria, nas embalagens de lata, polietileno tereftalato (PET), copos e garrações, nas categorias de refrigerantes, água mineral e energético.

A metodologia aplicada será para gerar embasamento para a definição do processo de previsão de vendas, seleção dos modelos mais aderentes e seus controles.

3.1 - SITUAÇÃO ATUAL DO OBJETO DE ESTUDO

CORRÊA *et al.* (2019), inclui a habilidade para prever demanda como uma área importante no processo de gestão de demanda, pois se faz necessário usar ferramentas adequadas, envolvendo a manutenção de dados históricos de vendas, assim como, informações que expliquem suas variações do passado capaz de derivar daí uma estimativa da demanda futura.

As etapas envolvidas nesta dissertação se embasam por dois aspectos: tipo de pesquisa e descrição das etapas, técnicas e ferramentas utilizadas para atingir os objetivos estabelecidos. Logo, este trabalho parte da escolha da metodologia de pesquisa explicativa, embasada em estudos descritivos e exploratórios, com a intenção de desenvolver um modelo de previsão de vendas para contribuir com a tomada de decisão da empresa.

Considerando a estrutura do Polo Industrial de Manaus (PIM), com uma diversidade ímpar de produtos desenvolvidos e produzidos nessa região, optou-se como objeto de estudo uma empresa regional do ramo de bebidas.

O processo estabelecido pela empresa, ao início do estudo, era embasado pela experiência da diretoria comercial e pelo direcionamento dado pela área de controladoria para o faturamento anual, com uma periodicidade de análise intermitente. Não havia colaboração entre as áreas para se chegar a um consenso de resultado otimizado.

Sem utilização de nenhum sistema de previsão, ou mesmo, planilhas inteligentes que utilizam ferramentas estatísticas disponíveis no Microsoft Excel®, havendo oportunidade de utilização de modelos básicos para o processo, visando reduzir os erros de previsão e as variações.

Utilização apenas de um indicador de acompanhamento, variação real *versus* objetivo. Ausência de reuniões periódicas de alinhamento com as áreas pares ou impactadas pelo planejamento. O consenso com a área comercial, para a inclusão da expertise na análise dos dados, era inexistente. O indicador para acompanhamento do resultado era, tão somente, o percentual de atingimento, que não supria a necessidade de novas análises. As previsões de volume são elaboradas utilizando somente a experiência do diretor comercial, ao invés de serem colaboradas pelas áreas comerciais e validada pela indústria, para estruturação do planejamento de produção, em alinhamento com a necessidade de estoques para atendimento do mercado, além de planejamento de necessidade de frota para distribuição.

O processo atual de planejamento da empresa em análise está desenhado conforme a Figura 3.1.

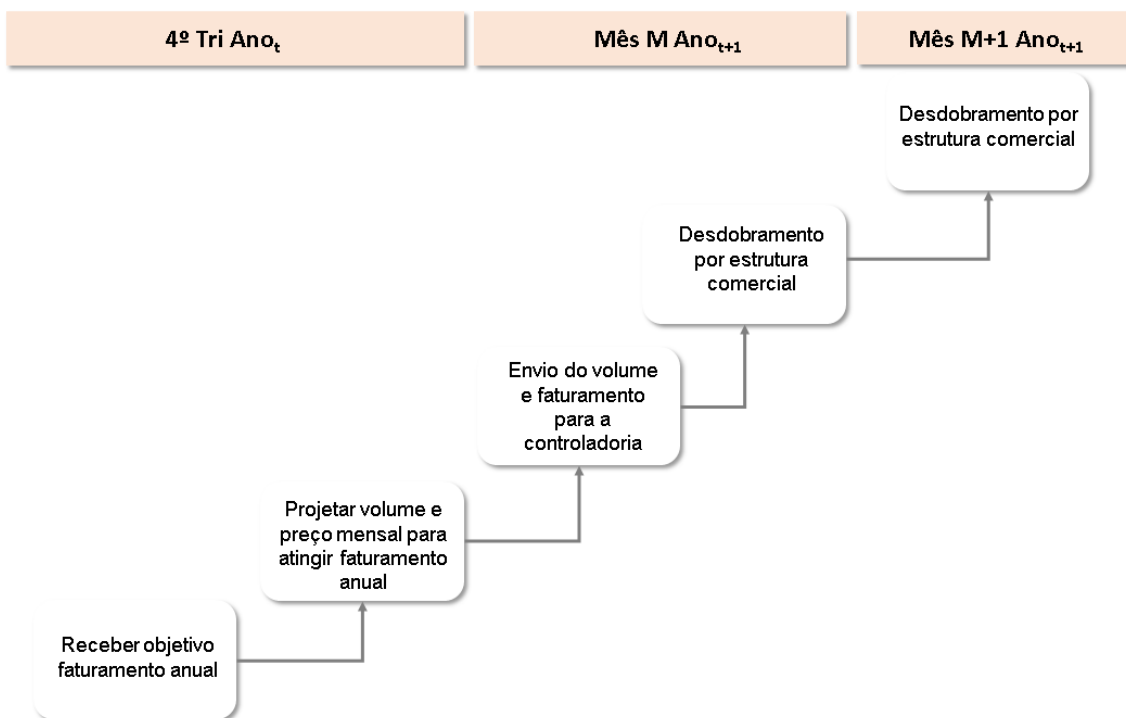


Figura 3.1 - Processo atual de planejamento da empresa em análise.

O direcionamento da empresa está para o desenvolvimento do planejamento estratégico, onde um dos objetivos é implantar o processo de previsão de vendas com

indicadores adequados ao negócio e tendo como visão de futuro a integração entre as áreas. Apesar do engajamento da alta direção, ainda há a necessidade de uma mudança de mapa mental das áreas envolvidas no processo para atingimento dos objetivos.

Para direcionamento do estudo foi realizado um diagnóstico e, os principais pontos abordados foram os que são descritos a seguir:

1. A estrutura atual do processo não proporciona uma boa visibilidade dos impactos que decisões isoladas podem vir a causar em outras áreas, dessa forma avaliações desse tipo de impacto são feitas de forma tácita;
2. Existe boa vontade em colaborar, mas os processos não estruturados não contribuem para resultados factíveis.
3. A previsão de vendas é desagregada por *SKU*, o que pode gerar erros de previsão significativos e torna mais lento o processo de liberação para área comercial;
4. Atualmente a maioria das informações necessárias para o planejamento não estão disponíveis no sistema, ou não possuem histórico registrado;
5. Agenda de reuniões para alinhamento, colaboração e consenso.

3.2 - ETAPA INICIAL PARA AJUSTE DO PROCESSO

Para ajuste do processo, na etapa inicial foram feitas entrevistas com as áreas envolvidas, para avaliar o impacto do processo de previsão de vendas em suas áreas e a necessidade de visão de futuro, conforme Tabela 3.1:

Tabela 3.1 - Áreas e necessidades – Resumo do levantamento.

Áreas envolvidas	Visão	Necessidade
Comercial	M+1	Direcionamento para objetivo de vendas
Industrial	M+3	Avaliação capacidade produtiva
Compras	M+3	Necessidade de matéria prima e produtos de terceiros
Estoque	M+3	Capacidade de Armazenamento
Logística	M+3	Necessidade de frota de distribuição
Controladoria	M+3	Análise de rentabilidade e margem bruta

As observações feitas foram conforme descritas a seguir:

A área comercial tem como base a previsão de vendas para direcionamento do objetivo comercial e cálculo dos indicadores que compõem o valor da variável paga a equipe, além de ser um direcionador para estabelecer as estratégias de mercado.

A indústria necessita avaliar se tem capacidade de produção necessária para atender a previsão de vendas, ou se planejar para obtê-la com o planejamento de produção.

Compras irá planejar e programar a necessidade de aquisição de matéria-prima para a quantidade que será produzida pela indústria, além da aquisição de produtos industrializados por terceiros.

A capacidade de armazenamento é parte importante neste processo, pela disponibilidade de espaço e estrutura para atender a movimentação de carga para o mercado ou entre estoques.

Logística irá avaliar a frota disponível, por perfil de veículo e a quantidade de veículos aptos disponíveis para atender a previsão de vendas.

A controladoria irá simular a rentabilidade do negócio na visão disponibilizada, a nível de SKU, entregando o demonstrativo de resultado alcançado com a projeção futura.

Baseado neste levantamento nas áreas envolvidas houve o redesenho do processo previsão de vendas, com foco em atender as pautas levantadas nas entrevistas realizadas.

3.3 - ESCOLHA DO MODELO DE PREVISÃO

A sequência das etapas propostas, desde a atualização dos dados com análise dos indicadores até a publicação dos dados, ampara o entendimento de como o processo funciona, com o desafio de que todas as áreas interajam entre si.

Para análise e escolha do modelo, foram utilizados 36 períodos de dados, na embalagem de refrigerante de Pet 2L. O estudo utilizou métodos quantitativos e previsões de séries temporais, cinco métodos foram avaliados:

- Média Móvel;
- Suavização exponencial simples;
- Suavização exponencial dupla;

- Tendência Linear;
- Holt Winters.

CAPÍTULO 4

RESULTADOS E DISCUSSÃO

4.1 - RESULTADOS ALCANÇADOS

4.1.1 - Média móvel

A média móvel tende a suavizar os dados observados e, para esta análise, foram observados 36 períodos de volume de Pet 2L e gerados resultados para N igual a 2, 3 e 4.

Para contribuir com a análise, foram gerados os gráficos, utilizando o software Minitab®, onde se compara os dados reais e os valores previstos, onde é possível observar a sazonalidade, os níveis de vendas e os ciclos das vendas. Na Figura 4.1 se compara os dados reais versus o previsto, para N=2, com DAM (Desvio Absoluto Médio) de 19.970.




Figura 4.1 - Comparativo entre real e previsto – Média móvel N=2.

Na Tabela 4.1, organizada usando Excel®, para os 36 dados coletados o MAPE, utilizado como indicador de acurácia do método da média móvel para N=2, é de 14,8%, eles foram alcançados utilizando os dados observados que estão na coluna com título de

P2L versus os valores previstos que está na coluna com título de predição. Os erros dos dados em análise se dão pela diferença entre o valor previsto e o valor observado.

Tabela 4.1 - Saída de dados para média móvel para N=2.

Período	P2L	MM	Predição	Erro	MPE	MAPE	Período	P2L	MM	Predição	Erro	MPE	MAPE
1	115.437						19	136.561	121.564	113.103	23.459	-17,2%	17,2%
2	90.751	103.094					20	144.573	140.567	121.564	23.010	-15,9%	15,9%
3	103.431	97.091	103.094	337	-0,3%	0,3%	21	142.394	143.484	140.567	1.827	-1,3%	1,3%
4	102.471	102.951	97.091	5.380	-5,3%	5,3%	22	182.924	162.659	143.484	39.441	-21,6%	21,6%
5	120.176	111.324	102.951	17.225	-14,3%	14,3%	23	149.331	166.128	162.659	- 13.328	8,9%	8,9%
6	111.377	115.777	111.324	54	0,0%	0,0%	24	189.817	169.574	166.128	23.690	-12,5%	12,5%
7	130.838	121.108	115.777	15.062	-11,5%	11,5%	25	131.707	160.762	169.574	- 37.867	28,8%	28,8%
8	128.318	129.578	121.108	7.211	-5,6%	5,6%	26	118.278	124.993	160.762	- 42.484	35,9%	35,9%
9	154.496	141.407	129.578	24.918	-16,1%	16,1%	27	116.307	117.293	124.993	- 8.686	7,5%	7,5%
10	164.226	159.361	141.407	22.819	-13,9%	13,9%	28	105.603	110.955	117.293	- 11.690	11,1%	11,1%
11	133.774	149.000	159.361	- 25.587	19,1%	19,1%	29	117.125	111.364	110.955	6.170	-5,3%	5,3%
12	195.814	164.794	149.000	46.814	-23,9%	23,9%	30	114.914	116.020	111.364	3.550	-3,1%	3,1%
13	97.842	146.828	164.794	- 66.952	68,4%	68,4%	31	128.641	121.778	116.020	12.622	-9,8%	9,8%
14	99.935	98.889	146.828	- 46.893	46,9%	46,9%	32	154.466	141.554	121.778	32.689	-21,2%	21,2%
15	102.703	101.319	98.889	3.815	-3,7%	3,7%	33	147.481	150.974	141.554	5.928	-4,0%	4,0%
16	114.881	108.792	101.319	13.562	-11,8%	11,8%	34	154.849	151.165	150.974	3.876	-2,5%	2,5%
17	119.639	117.260	108.792	10.847	-9,1%	9,1%	35	137.466	146.158	151.165	- 13.699	10,0%	10,0%
18	106.566	113.103	117.260	- 10.694	10,0%	10,0%	36	202.955	170.211	146.158	56.798	-28,0%	28,0%
												-0,3%	15%

No comparativo, para o método da média móvel para N=3, na Figura 4.2 o DAM processado é de 23.115 e, visualmente, se verifica que os dados previstos possuem a mesma sazonalidade dos dados reais, mas com um distanciamento.




Figura 4.2 - Comparativo entre real e previsto – Média móvel N=3.

Adicional a análise gráfica, o MAPE para este método é de 17,2%, maior 2,9 pontos percentuais se comparado com a análise para N=2, conforme Tabela 4.2, onde o MPE, erro médio percentual é de -0,4%

Tabela 4.2 - Saída de dados para média móvel para N=3.

Período	P2L	MM	Predição	Erro	MPE	MAPE	Período	P2L	MM	Predição	Erro	MPE	MAPE
1	115.437						19	136.561	120.922	113.695	22.866	-16,7%	16,7%
2	90.751						20	144.573	129.233	120.922	23.651	-16,4%	16,4%
3	103.431	103.206					21	142.394	141.176	129.233	13.161	-9,2%	9,2%
4	102.471	98.884	103.206	- 735	0,7%	0,7%	22	182.924	156.630	141.176	41.748	-22,8%	22,8%
5	120.176	108.693	98.884	21.292	-17,7%	17,7%	23	149.331	158.216	156.630	- 7.299	4,9%	4,9%
6	111.377	111.341	108.693	2.684	-2,4%	2,4%	24	189.817	174.024	158.216	31.601	-16,6%	16,6%
7	130.838	120.797	111.341	19.497	-14,9%	14,9%	25	131.707	156.952	174.024	- 42.317	32,1%	32,1%
8	128.318	123.511	120.797	7.521	-5,9%	5,9%	26	118.278	146.601	156.952	- 38.674	32,7%	32,7%
9	154.496	137.884	123.511	30.985	-20,1%	20,1%	27	116.307	122.097	146.601	- 30.294	26,0%	26,0%
10	164.226	149.013	137.884	26.342	-16,0%	16,0%	28	105.603	113.396	122.097	- 16.494	15,6%	15,6%
11	133.774	150.832	149.013	- 15.239	11,4%	11,4%	29	117.125	113.012	113.396	3.729	-3,2%	3,2%
12	195.814	164.605	150.832	44.982	-23,0%	23,0%	30	114.914	112.547	113.012	1.902	-1,7%	1,7%
13	97.842	142.477	164.605	- 66.763	68,2%	68,2%	31	128.641	120.227	112.547	16.094	-12,5%	12,5%
14	99.935	131.197	142.477	- 42.542	42,6%	42,6%	32	154.466	132.674	120.227	34.239	-22,2%	22,2%
15	102.703	100.160	131.197	- 28.494	27,7%	27,7%	33	147.481	143.529	132.674	14.807	-10,0%	10,0%
16	114.881	105.840	100.160	14.721	-12,8%	12,8%	34	154.849	152.265	143.529	11.320	-7,3%	7,3%
17	119.639	112.408	105.840	13.799	-11,5%	11,5%	35	137.466	146.599	152.265	- 14.799	10,8%	10,8%
18	106.566	113.695	112.408	- 5.842	5,5%	5,5%	36	202.955	165.090	146.599	56.356	-27,8%	27,8%
												-0,4%	17%

Para N=4, conforme baseado na Figura 4.3, temos um DAM de 25.188, o maior entre os 3 Ns gerados e com isso tem-se um descolamento maior entre a curva de dados reais versus a curva de dados previstos.




Figura 4.3 - Comparativo entre real e previsto – Média móvel N=4.

Complementar a análise gráfica, baseado no MAPE igual 19% para N=4 conclui-se que este método, até o momento, é o mais inadequado para aplicação, de acordo com a Tabela 4.3, abaixo, conforme observado os valores previstos se deslocam conforme o valor do N e sempre o primeiro valor previsto é igual ao primeiro valor da primeira média móvel, na Tabela 4.3 temos que a primeira média móvel é igual a 103.029 é igual ao primeiro valor previsto.

Tabela 4.3 - Saída de dados para média móvel para N=4.

Período	P2L	MM	Predição	Erro	MPE	MAPE	Período	P2L	MM	Predição	Erro	MPE	MAPE
1	115.437						19	136.561	119.412	110.947	25.614	-18,8%	18,8%
2	90.751						20	144.573	126.835	119.412	25.161	-17,4%	17,4%
3	103.431						21	142.394	132.524	126.835	15.559	-10,9%	10,9%
4	102.471	103.023					22	182.924	151.613	132.524	50.401	-27,6%	27,6%
5	120.176	104.207	103.023	17.154	-14,3%	14,3%	23	149.331	154.806	151.613	- 2.282	1,5%	1,5%
6	111.377	109.364	104.207	7.170	-6,4%	6,4%	24	189.817	166.117	154.806	35.012	-18,4%	18,4%
7	130.838	116.216	109.364	21.474	-16,4%	16,4%	25	131.707	163.445	166.117	- 34.410	26,1%	26,1%
8	128.318	122.677	116.216	12.103	-9,4%	9,4%	26	118.278	147.283	163.445	- 45.167	38,2%	38,2%
9	154.496	131.257	122.677	31.819	-20,6%	20,6%	27	116.307	139.027	147.283	- 30.976	26,6%	26,6%
10	164.226	144.470	131.257	32.969	-20,1%	20,1%	28	105.603	117.974	139.027	- 33.424	31,7%	31,7%
11	133.774	145.204	144.470	- 10.696	8,0%	8,0%	29	117.125	114.328	117.974	- 849	0,7%	0,7%
12	195.814	162.078	145.204	50.611	-25,8%	25,8%	30	114.914	113.487	114.328	586	-0,5%	0,5%
13	97.842	147.914	162.078	- 64.236	65,7%	65,7%	31	128.641	116.571	113.487	15.154	-11,8%	11,8%
14	99.935	131.841	147.914	- 47.979	48,0%	48,0%	32	154.466	128.787	116.571	37.895	-24,5%	24,5%
15	102.703	124.074	131.841	- 29.138	28,4%	28,4%	33	147.481	136.376	128.787	18.695	-12,7%	12,7%
16	114.881	103.840	124.074	- 9.193	8,0%	8,0%	34	154.849	146.359	136.376	18.474	-11,9%	11,9%
17	119.639	109.290	103.840	15.799	-13,2%	13,2%	35	137.466	148.566	146.359	- 8.893	6,5%	6,5%
18	106.566	110.947	109.290	- 2.724	2,6%	2,6%	36	202.955	160.688	148.566	54.390	-26,8%	26,8%
												-0,5%	19%

Até o momento, com base no MPE e MAPE, no comparativo das médias móveis calculadas utilizando o software Minitab®, N=2 tem o menor MAPE, 15%, ou seja, o que apresenta o menor erro médio absoluto das 3 análises, indicando ser o mais indicado para uso, até o momento. Em continuidade a análise do método de média móvel, há a análise gráfica do resíduo da média móvel para N=2, representando uma variação natural dos dados e que a dispersão dos resíduos aumenta conforme o valor previsto, conforme Figura 4.4 apresentada a seguir.




Figura 4.4 - Gráfico de resíduos – Média móvel – N=2.

Nas Figuras 4.5 e 4.6, na sequência, que representam a análise gráfica dos resíduos obtidos para N=3 e N=4, respectivamente, com a utilização do software Minitab®, temos a dispersão dos valores de resíduos e os valores ajustados, a análise gráfica indica que eles estão dispersos aleatoriamente, ou seja, podendo o modelo escolhido ser adequado ao estudo e apresentam o mesmo comportamento, que é há uma variação natural dos dados e que a dispersão dos resíduos aumenta conforme o valor previsto.




Figura 4.5 - Gráfico de resíduos – Média móvel – N=3.




Figura 4.6 - Gráfico de resíduos – Média móvel – N=4.

4.1.2 - Suavização exponencial simples

Para aplicação do modelo de suavização exponencial, foi utilizando o software Minitab® para gerar a saída de dados, o mesmo atribuiu para análise um α igual a 0,552330, para obtenção do menor erro absoluto médio possível, onde o mesmo tem que possuir uma variação entre 0 e 1.

Pela análise gráfica comparativa entre os dados reais e os dados previstos, conforme Figura 4.7, verifica-se que eles possuem a mesma sazonalidade e tendência, porém, com um deslocamento entre as duas curvas. É possível identificar que os valores suavizados pelo modelo reduzem os impactos de picos e vales com um DAM (Desvio Médio Absoluto) de 20.444.

Para o experimento foram considerados 36 períodos de dados de volume de vendas do P2L.




Figura 4.7 - Comparativo real *versus* previsto – Suavização exponencial.

Os dados resultantes da saída do Minitab® foram organizados utilizando o Microsoft Excel® e que estão explicitados na Tabela 4.4 onde o MAPE, que está sendo usado como medida de acurácia, é de 15,2%. Também na Tabela 4.4 pode ser observado o valor suavizado do modelo e o valor predito, este modelo pondera os dados dando um valor de maior representatividade para os dados mais recentes. A coluna do erro é dada pela diferença entre o dado observado e o dado predito e o erro percentual médio (MPE), que é a relação percentual entre o valor predito e o valor observado, é de 0,2%.

Tabela 4.4 - Saída de dados de suavização exponencial.

Período	P2L	Suave	Predição	Erro	MPE	MAPE	Período	P2L	Suave	Predição	Erro	MPE	MAPE
1	115.437	111.921	107.584	7.854	-6,8%	6,8%	19	136.561	125.038	110.821	25.740	-18,8%	18,8%
2	90.751	100.228	111.921	- 21.170	23,3%	23,3%	20	144.573	135.828	125.038	19.535	-13,5%	13,5%
3	103.431	101.997	100.228	3.203	-3,1%	3,1%	21	142.394	139.455	135.828	6.566	-4,6%	4,6%
4	102.471	102.259	101.997	474	-0,5%	0,5%	22	182.924	163.464	139.455	43.470	-23,8%	23,8%
5	120.176	112.155	102.259	17.917	-14,9%	14,9%	23	149.331	155.658	163.464	- 14.133	9,5%	9,5%
6	111.377	111.725	112.155	- 778	0,7%	0,7%	24	189.817	174.525	155.658	34.159	-18,0%	18,0%
7	130.838	122.282	111.725	19.113	-14,6%	14,6%	25	131.707	150.875	174.525	- 42.818	32,5%	32,5%
8	128.318	125.616	122.282	6.036	-4,7%	4,7%	26	118.278	132.871	150.875	- 32.597	27,6%	27,6%
9	154.496	141.567	125.616	28.880	-18,7%	18,7%	27	116.307	123.722	132.871	- 16.564	14,2%	14,2%
10	164.226	154.082	141.567	22.659	-13,8%	13,8%	28	105.603	113.714	123.722	- 18.119	17,2%	17,2%
11	133.774	142.865	154.082	- 20.308	15,2%	15,2%	29	117.125	115.598	113.714	3.411	-2,9%	2,9%
12	195.814	172.110	142.865	52.949	-27,0%	27,0%	30	114.914	115.220	115.598	- 684	0,6%	0,6%
13	97.842	131.090	172.110	- 74.269	75,9%	75,9%	31	128.641	122.633	115.220	13.421	-10,4%	10,4%
14	99.935	113.882	131.090	- 31.155	31,2%	31,2%	32	154.466	140.215	122.633	31.833	-20,6%	20,6%
15	102.703	107.708	113.882	- 11.179	10,9%	10,9%	33	147.481	144.228	140.215	7.266	-4,9%	4,9%
16	114.881	111.670	107.708	7.174	-6,2%	6,2%	34	154.849	150.094	144.228	10.621	-6,9%	6,9%
17	119.639	116.071	111.670	7.969	-6,7%	6,7%	35	137.466	143.119	150.094	- 12.628	9,2%	9,2%
18	106.566	110.821	116.071	- 9.505	8,9%	8,9%	36	202.955	176.168	143.119	59.836	-29,5%	29,5%
												0,2%	15%

Na Figura 4.8, temos a dispersão dos valores ajustados versus os resíduos, onde se conclui que eles estão dispersos aleatoriamente em torno de zero, indicando o comportamento esperado para a distribuição dos erros ou que o modelo é adequado ao estudo.




Figura 4.8 - Gráfico resíduo – Suavização exponencial.

4.1.3 - Suavização exponencial dupla

Para aplicação do modelo de suavização exponencial dupla, foi utilizando o software Minitab® para gerar a saída de dados, o mesmo atribuiu para análise um α , que representa o nível, igual a 0,635063, para obtenção do menor erro absoluto médio possível, onde o mesmo tem que possuir uma variação entre 0 e 1, e um γ , que representa a tendência, igual a 0,023277.

Para o experimento foram considerados 36 períodos de dados de volume de vendas do P2L.

Pela análise gráfica comparativa entre os dados reais e os dados previstos, conforme Figura 4.9, verifica-se que eles possuem a mesma sazonalidade e tendência, porém, com uma aderência entre as duas curvas. É possível identificar que os valores suavizados pelo modelo reduzem os impactos de picos e vales com um DAM (Desvio Médio Absoluto) de 19.767.




Figura 4.9 - Comparativo real *versus* previsto – Suavização exponencial dupla.

Os dados resultantes da saída do Minitab® foram organizados utilizando o Microsoft Excel® e que estão explicitados na Tabela 4.5 onde o MAPE, que está sendo usado como medida de acurácia, é de 15%, os dados previstos são resultantes de dupla suavização.

Tabela 4.5 - Saída de dados de suavização exponencial dupla.

Período	P2L	Suave	Predição	Erro	MPE	MAPE	Período	P2L	Suave	Predição	Erro	MPE	MAPE
1	115.437	107.905	94.798	20.639	-17,9%	17,9%	19	136.561	128.606	114.762	21.799	-16,0%	16,0%
2	90.751	95.328	103.293	- 12.542	13,8%	13,8%	20	144.573	139.884	131.725	12.848	-8,9%	8,9%
3	103.431	103.638	103.998	- 567	0,5%	0,5%	21	142.394	142.686	143.194	- 800	0,6%	0,6%
4	102.471	104.334	107.576	- 5.105	5,0%	5,0%	22	182.924	169.443	145.983	36.941	-20,2%	20,2%
5	120.176	115.804	108.197	11.980	-10,0%	10,0%	23	149.331	158.073	173.287	- 23.956	16,0%	16,0%
6	111.377	114.467	119.844	- 8.467	7,6%	7,6%	24	189.817	179.506	161.563	28.254	-14,9%	14,9%
7	130.838	126.292	118.381	12.457	-9,5%	9,5%	25	131.707	150.576	183.413	- 51.706	39,3%	39,3%
8	128.318	129.074	130.391	- 2.073	1,6%	1,6%	26	118.278	131.212	153.719	- 35.441	30,0%	30,0%
9	154.496	146.703	133.142	21.354	-13,8%	13,8%	27	116.307	122.702	133.831	- 17.524	15,1%	15,1%
10	164.226	159.431	151.087	13.139	-8,0%	8,0%	28	105.603	112.704	125.062	- 19.459	18,4%	18,4%
11	133.774	144.808	164.009	- 30.235	22,6%	22,6%	29	117.125	116.268	114.777	2.349	-2,0%	2,0%
12	195.814	178.708	148.939	46.875	-23,9%	23,9%	30	114.914	116.177	118.375	- 3.461	3,0%	3,0%
13	97.842	129.113	183.531	- 85.689	87,6%	87,6%	31	128.641	124.843	118.233	10.408	-8,1%	8,1%
14	99.935	111.881	132.670	- 32.735	32,8%	32,8%	32	154.466	144.462	127.052	27.414	-17,7%	17,7%
15	102.703	107.174	114.955	- 12.252	11,9%	11,9%	33	147.481	147.333	147.077	404	-0,3%	0,3%
16	114.881	113.124	110.066	4.815	-4,2%	4,2%	34	154.849	153.063	149.954	4.895	-3,2%	3,2%
17	119.639	118.343	116.087	3.552	-3,0%	3,0%	35	137.466	144.141	155.756	- 18.290	13,3%	13,3%
18	106.566	111.964	121.359	- 14.793	13,9%	13,9%	36	202.955	182.376	146.564	56.392	-27,8%	27,8%

3% 15%

Na Figura 4.8, temos a dispersão dos valores ajustados *versus* os resíduos, onde ser conclui que eles estão dispersos aleatoriamente em torno de zero, indicando o comportamento esperado para a distribuição dos erros ou que o modelo foi adequado ao estudo.

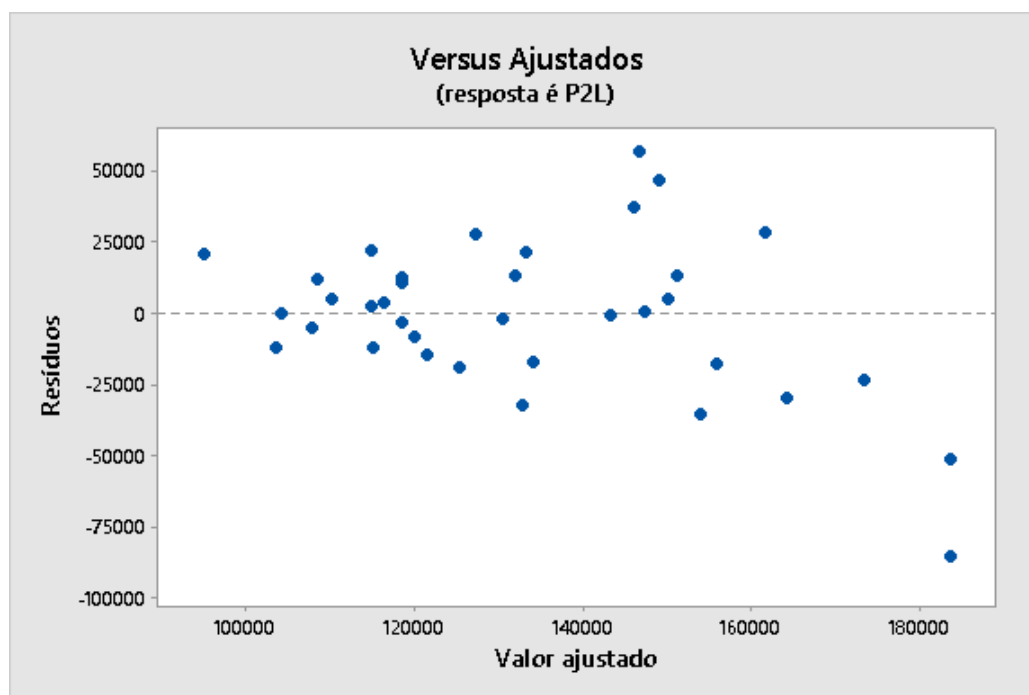


Figura 4.10 - Gráfico resíduo – Suavização exponencial dupla.

4.1.4 - Tendência linear

A Eq. (4.2) representa a tendência dos dados, obtida através do software Minitab®, que representa o volume de P2L, no período dos 36 meses é expressa a seguir:

$$Y_t = 114.087 + 992 \times t \quad (4.2)$$

Onde:

t é o período analisado.

Pela equação infere-se que, durante os 36 meses utilizados para embasamento da análise, houve um acréscimo de 992 unidades no volume. As estimativas para a tendência são exibidas na Tabela 4.7.

Na Tabela 4.6 há os dados alcançados com o modelo da Eq. (4.2), o MAPE, que é o indicador de acurácia utilizado, foi de 15,4%. Neste modelo temos os dados sem tendência que, em comparação aos modelos anteriores, é o mesmo cálculo do erro.

Tabela 4.6 - Saída de dados tendência linear.

Período	P2L	Tendência	Sem Tendência	MPE	MAPE	Período	P2L	Tendência	Sem Tendência	MPE	MAPE
1	115.437	115.079	358	-0,3%	0,3%	19	136.561	132.943	3.619	-2,6%	2,6%
2	90.751	116.072	- 25.321	27,9%	27,9%	20	144.573	133.935	10.638	-7,4%	7,4%
3	103.431	117.064	- 13.633	13,2%	13,2%	21	142.394	134.927	7.467	-5,2%	5,2%
4	102.471	118.057	- 15.586	15,2%	15,2%	22	182.924	135.920	47.004	-25,7%	25,7%
5	120.176	119.049	1.127	-0,9%	0,9%	23	149.331	136.912	12.419	-8,3%	8,3%
6	111.377	120.041	- 8.664	7,8%	7,8%	24	189.817	137.904	51.913	-27,3%	27,3%
7	130.838	121.034	9.804	-7,5%	7,5%	25	131.707	138.897	- 7.190	5,5%	5,5%
8	128.318	122.026	6.292	-4,9%	4,9%	26	118.278	139.889	- 21.611	18,3%	18,3%
9	154.496	123.019	31.477	-20,4%	20,4%	27	116.307	140.882	- 24.575	21,1%	21,1%
10	164.226	124.011	40.215	-24,5%	24,5%	28	105.603	141.874	- 36.271	34,3%	34,3%
11	133.774	125.003	8.771	-6,6%	6,6%	29	117.125	142.866	- 25.741	22,0%	22,0%
12	195.814	125.996	69.818	-35,7%	35,7%	30	114.914	143.859	- 28.945	25,2%	25,2%
13	97.842	126.988	- 29.146	29,8%	29,8%	31	128.641	144.851	- 16.210	12,6%	12,6%
14	99.935	127.981	- 28.046	28,1%	28,1%	32	154.466	145.844	8.622	-5,6%	5,6%
15	102.703	128.973	- 26.270	25,6%	25,6%	33	147.481	146.836	645	-0,4%	0,4%
16	114.881	129.965	- 15.084	13,1%	13,1%	34	154.849	147.828	7.021	-4,5%	4,5%
17	119.639	130.958	- 11.319	9,5%	9,5%	35	137.466	148.821	- 11.355	8,3%	8,3%
18	106.566	131.950	- 25.384	23,8%	23,8%	36	202.955	149.813	53.142	-26,2%	26,2%
										3,5%	15%

Apoiando a análise, na Figura 4.11 há a linha de tendência do modelo, com um DAM de 20.575.




Figura 4.11 - Análise de tendência para P2L.

Auxiliando na análise gráfica, há também a Figura 4.12 que é a distribuição dos resíduos do modelo versus o valor ajustado, onde identifica-se que os dados estão distribuídos aleatoriamente ao redor do eixo zero, para o qual há uma boa adequação da reta ajustada aos dados ou que o modelo escolhido foi adequado ao estudo.




Figura 4.12 - Resíduos – Tendência linear P2L.

4.1.5 - Holt Winters

Para este modelo foi utilizado o método multiplicativo, na Tabela 4.7 tem-se as constantes de suavização geradas pelo Minitab®, utilizando 36 períodos para embasamento do modelo.

Tabela 4.7 - Constantes de suavização.

α (nível)	0,2
γ (tendência)	0,2
δ (sazonal)	0,2

As constantes de suavização α , γ e δ são utilizadas para minimizar o erro absoluto médio do modelo Holt Winters. Ratificando, para gerar a saída de dados explicitada na Tabela 4.8, foram utilizados 36 períodos com o volume de P2L.

O MAPE, que está aplicado como indicador de acurácia, é de 19,6%, conforme Tabela 4.8, e até este momento é o modelo com maior erro de previsão percentual observado. Na coluna Suave temos os dados suavizados, com sazonalidade utilizando os parâmetros informados na Tabela 4.7.

Tabela 4.8 - Saída de dados Holt Winters.

Período	P2L	Suave	Predição	Erro	MPE	MAPE	Período	P2L	Suave	Predição	Erro	MPE	MAPE
1	115.437	108.177	105.588	9.849	-8,5%	8,5%	19	136.561	116.355	114.604	21.957	-16,1%	16,1%
2	90.751	103.769	101.652	- 10.901	12,0%	12,0%	20	144.573	114.648	113.806	30.767	-21,3%	21,3%
3	103.431	110.741	107.898	- 4.467	4,3%	4,3%	21	142.394	130.981	131.406	10.988	-7,7%	7,7%
4	102.471	101.085	98.232	4.240	-4,1%	4,1%	22	182.924	130.751	131.597	51.327	-28,1%	28,1%
5	120.176	92.557	90.049	30.127	-25,1%	25,1%	23	149.331	138.208	141.032	8.299	-5,6%	5,6%
6	111.377	108.140	106.674	4.703	-4,2%	4,2%	24	189.817	151.630	154.984	34.833	-18,4%	18,4%
7	130.838	103.046	101.822	29.016	-22,2%	22,2%	25	131.707	165.490	170.341	- 38.634	29,3%	29,3%
8	128.318	104.867	104.805	23.513	-18,3%	18,3%	26	118.278	151.149	154.222	- 35.944	30,4%	30,4%
9	154.496	118.192	119.141	35.355	-22,9%	22,9%	27	116.307	160.130	161.911	- 45.604	39,2%	39,2%
10	164.226	125.191	127.535	36.691	-22,3%	22,3%	28	105.603	145.197	145.156	- 39.553	37,5%	37,5%
11	133.774	130.310	133.992	- 218	0,2%	0,2%	29	117.125	127.423	125.916	- 8.791	7,5%	7,5%
12	195.814	146.034	150.040	45.774	-23,4%	23,4%	30	114.914	134.001	131.994	- 17.080	14,9%	14,9%
13	97.842	157.712	163.494	- 65.652	67,1%	67,1%	31	128.641	122.400	119.840	8.802	-6,8%	6,8%
14	99.935	139.180	142.101	- 42.166	42,2%	42,2%	32	154.466	117.014	114.889	39.577	-25,6%	25,6%
15	102.703	152.472	153.880	- 51.177	49,8%	49,8%	33	147.481	131.210	130.631	16.851	-11,4%	11,4%
16	114.881	126.544	125.981	- 11.100	9,7%	9,7%	34	154.849	131.841	131.935	22.914	-14,8%	14,8%
17	119.639	116.943	115.992	3.647	-3,0%	3,0%	35	137.466	136.561	137.572	- 106	0,1%	0,1%
18	106.566	132.226	131.313	- 24.748	23,2%	23,2%	36	202.955	142.571	143.613	59.342	-29,2%	29,2%
												0,8%	20%

Atentando a para a Figura 4.13, constata-se que a linha dos dados ajustados é suavizada pelo modelo, contudo, o DAM (Desvio médio absoluto) calculado é de 25.696, cooperando com a análise de maior erro de previsão, aqui há também o maior DAM dos modelos observados até o momento.




Figura 4.13 - Saída de dados método Holt Winters.

Na Figura 4.14, nota-se que os dados de dispersão dos resíduos são semelhantes a forma de um funil, onde indica que a variabilidade dos resíduos não é constante, que a mesma é uma função crescente de y , aumentando à medida que ocorrem acréscimos na variável-resposta, ou seja, que o modelo pode ter desconsiderado a tendência dos dados.




Figura 4.14 - Resíduos do método Holt Winters.

4.1.6 - Comparativo entre os modelos de previsão

Neste tópico foi comparado os modelos: média móvel, suavização exponencial, tendência linear e holt winter.

Estruturando o comparativo entre os métodos de previsão, a tabela 4.9 demonstra que os MAPEs calculados para cada um dos métodos. O MAPE foi utilizado como indicador de acurácia para se obter o método com o menor erro de previsão.

Os três menores MAPEs foram o de média móvel N=2, Suavização exponencial e Tendência Linear.

Tabela 4.9 - Comparativo entre os modelos.

Modelos	Desvio Médio	MAPE
Média Móvel N=2	19.970	15%
Média Móvel N=3	23.115	17%
Média Móvel N=4	25.188	19%
Suavização Exponencial Simples	20.444	15%
Suavização Exponencial Dupla	19.767	15%
Tendência Linear	20.575	15%
Holt Winter	25.686	20%

4.2 - PROCESSO DE PREVISÃO DE VENDAS AJUSTADO

A seguir são descritas as novas etapas, que podem ser visualizadas de forma resumida na Figura 4.13:

Etapa 1 – Nesta etapa é feita a atualização da base dos dados histórico, inserção de um produto novo ou exclusão de um produto a ser descontinuado. É feito a apuração das diferenças entre os planos acompanhado das respectivas justificativas. Em caso de uma nova área de atuação, as premissas para a projeção dessa nova área são consideradas. Análise do comportamento histórico e dos indicadores de acurácia servem como parâmetro para revisão e retroalimentação das bases a serem utilizadas para a nova projeção.

Etapa 2 – Projeção da previsão para os meses subsequentes, é feita no primeiro momento baseado nos históricos e em modelos estatísticos estabelecidos através do menor erro de previsão. Adicionado a isso, também é avaliado o resultado em

comparativo as premissas, inserção de novos produtos e expertise do previsor. Nesta etapa são realizadas as consolidações dos dados para a reunião de consenso.

Etapa 3 – Na 4ª semana do mês são realizadas reuniões para a colaboração das áreas impactadas pela previsão de vendas. O objetivo é, também, considerar para a análise a expertise das áreas envolvidas, considerando os planos de:

- Produção;
- Vendas;
- Marketing;
- Distribuição capital, interior do estado e outros estados.

Devem ser considerados os produtos críticos, como por exemplo produtos que continuamente necessitam de ações para escoar no mercado, ou novos produtos nos processos produtivo e de comercialização, além também de alinhamento com a área de compras para avaliar o plano de atendimento dos fornecedores de insumos e/ou produtos acabados, caso possam impactar no planejamento acordado.

Etapa 4 – Nesta etapa, após alinhamento dos planos associado as projeções com estudo de soluções viáveis, se faz necessário uma reunião prévia com as áreas impactadas. Nesta reunião devem ser expostas as principais decisões tomadas, listar principais pontos de conflitos que devem ser encaminhados a alta direção com as possíveis soluções.

Etapa 5 – Deve ser realizada uma reunião para a alta direção contendo o planejamento final de vendas, embasado no modelo estatístico adicionado dos planos que foram alinhados com as demais áreas impactadas. Caso não se tenha chegado a um consenso acerca de algum ponto de divergência específico, este deverá constar na pauta, bem como suas alternativas de solução.

A etapa final é a publicação dos dados aprovados pela diretoria, para os clientes desse processo e áreas impactadas.

Para suporte neste processo é disponibilizado um calendário com as datas marco para acompanhamento.

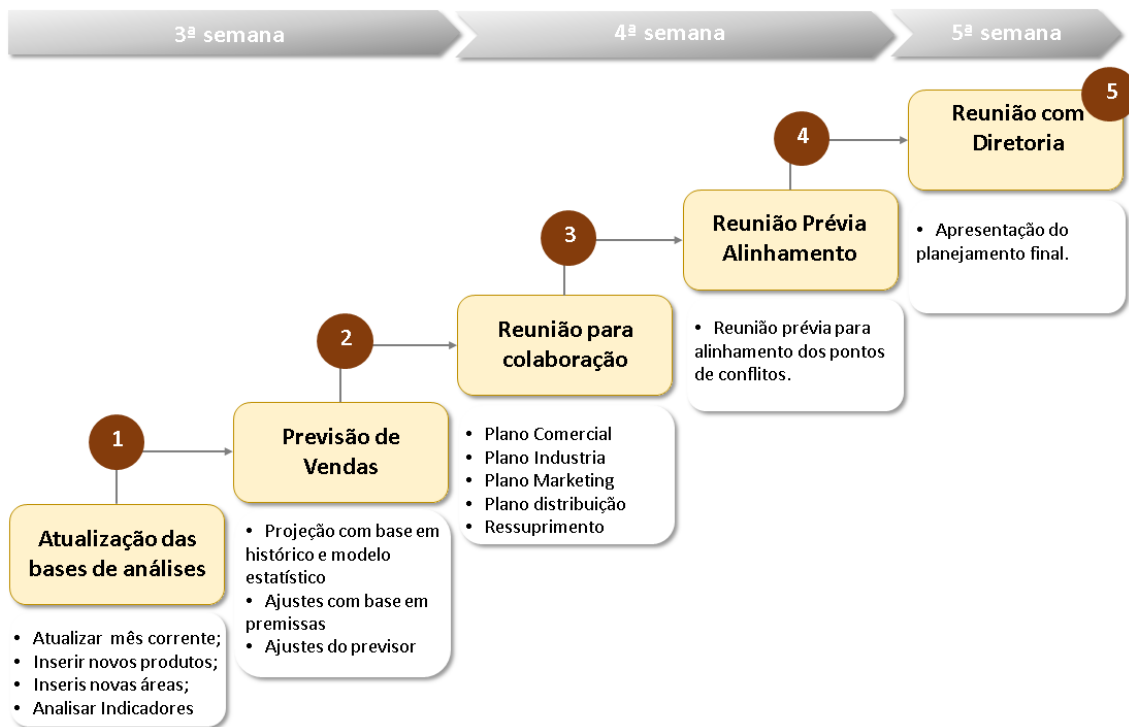


Figura 4.15 - Processo mensal de previsão de vendas resumido – Ajustado.

CAPÍTULO 5

CONCLUSÕES E SUGESTÕES

5.1 - CONCLUSÕES

A iniciativa de se estruturar um processo de previsão de vendas é de grande valia nos momentos atuais, partindo de uma conscientização por parte de todas as áreas impactadas e envolvidas, em busca de otimização de processo, de utilização de ferramentas e metodologias adequadas.

O estudo de caso desenvolvido teve como objetivo inicial o levantamento de dados necessários para o desenvolvimento do modelo de previsão de vendas, que foi alcançado através da coleta de dados dos volumes das bebidas de refrigerante na embalagem de polietileno de 2 litros, embalagem utilizada para análise devido ela ser a maior participação no faturamento da empresa em análise. Foram observados 36 períodos, referente a 3 anos.

Fundamentado nas principais metodologias de previsão de demanda norteadas por estudiosos das áreas, foram realizadas análises e comparativos de modelos e métodos estatístico de previsão de vendas. Ao julgar a sua aplicabilidade nos dados examinados, atingimos o objetivo de determinar um modelo de previsão de vendas, pois se encontrou três possíveis modelos a serem utilizados: Média Móvel para $N=2$, Suavização Exponencial e Tendência Linear, sendo escolhido para aplicação o método de Suavização Exponencial.

O indicador de acurácia elegido para o estudo e uso da empresa em análise foi o MAPE (Médias dos erros percentuais absolutos) por ser de fácil usabilidade e compreensão.

Este estudo também propôs expor um novo processo de previsão de vendas, que foi reescrito com a colaboração das áreas impactadas, gerando sinergia, engajamento e, principalmente, reserva de tempo para o planejamento integrado da empresa. Cada etapa foi desenhada com foco nos objetivos a serem entregues.

A empresa utilizada é de médio porte, e durante muitos períodos deixou de se utilizar de uma previsão de vendas em um processo estruturado, em um primeiro momento, por não haver mão de obra dedicada para o mesmo e, nos momentos seguintes, por não terem embarcado os conhecimentos necessários para as tratativas que

deveriam ser dadas, desde a aquisição, ou não, de um software de previsão até a definição de um painel de indicadores.

Entende-se que o material contribuiu para atingir os objetivos traçados, apresentando de forma clara e simplificado suas análises e resultados.

5.2 - SUGESTÕES

Ponderando que o desafio permanente, dentro do processo de previsão de vendas, é otimizar a assertividade do planejamento e reduzir o erro de previsão ainda há espaço de evolução para estudos futuros. Algo potencial para estudo futuro é a viabilidade de criação de um sistema de suporte ao processo e que ele tenha usabilidade, flexibilidade e eficiência de uso direcionado para empresas de pequeno e médio porte que não possuam caixa suficiente para investimento em planejamento e desenvolvimento.

O estudo tratou somente da previsão de vendas com foco em volume, uma outra perspectiva para continuidade deste estudo é a expansão do mesmo para os demais *SKUs* do portfólio da empresa, avaliação de outros modelos, métodos considerando a utilização de outras variáveis que impactam no planejamento da previsão de vendas, tais como, clima e tempo, indicadores econômicos e preço, além de técnicas que se utilizem de inteligência computacional.

REFERÊNCIAS BIBLIOGRÁFICAS

ALVES, C. C.; HOEPERS, E.; CORAZZA, E. J.; SANTOS, G. J.; CRISTOFOLINI, R.; CRUZ, A. C. Aplicação de métodos estatísticos com suavização exponencial dupla e tripla para previsão de demanda na gestão de estoques. **Revista científica eletrônica de engenharia de produção**, Florianópolis – SC, v.19, n.3, p. 1001 – 1026, 2019.

BALLOU, R. H. **Gerenciamento da cadeia de suprimentos/logística empresarial**. 5ª. ed, Porto Alegre: Bookman, 2006.

BATISTA, V. C. **Previsão de vendas: Um estudo no varejo de vestuário**. Dissertação de Mestrado - Universidade Federal do Rio Grande do Sul, Escola de Engenharia. Porto Alegre, 2017.

BAZIONIS, I. K.; GEORGILAKIS, P. S. **Review of Deterministic and Probabilistic Wind Power Forecasting: Models, Methods, and Future Research**. *Electricity* 2021, 2, 13-47.

BLOCK, N. C. S.; BOMBANA, G. A.; TESSAROLO, P. H. F.; FERREIRA, J.; ROCHA, R. P. R. Previsão de demanda: Uma análise em uma empresa de equipamentos agrícolas. **XI Encontro de Engenharia de Produção Agroindustrial**, Paraná: EEPA, 2017.

BRUNATO, P. B.; HENNING, E.; WALTER, O. M. F. C.; TORTORELLA, G. L. Aplicación de métodos de previsión de series temporales um êtil iat êtilxtil. **Revista Espacios**, Vol. 37 (Nº 37) Ano 2016. Pág. 19.

CIEAM: **Setor de Bebidas mantém estabilidade no Amazonas**. Disponível em: <<https://cieam.com.br/setor-de-bebidas-mantem-estabilidade-no-amazonas>>. Acesso em: 26 de janeiro de 2022.

CHASE, R. B.; JACOBS, F. R.; AQUILANO, N. T. **Administração da produção para a vantagem competitiva**. 10 ed. Porto Alegre: Bookman, 2006.

CORRÊA, H. L.; GIANESI, I. G. N.; CAON, M. **Planejamento, programação e controle da produção: MRP II / ERP: conceitos, uso e implantação**. 6 ed São Paulo: Atlas, 2019.

COSTA, J. C. **Planejamento, programação e controle de produção**. Londrina: Editora e Distribuidora Educacional S.A., 2016.

DOANE, D. P.; SEWARD, L. E. **Estatística aplicada a administração e economia**. 4 ed. Porto Alegre: AMGH, 2014.

GIRARDI, G. **Modelo integrado para previsão de vendas como uma ferramenta de competitividade: Um estudo de caso em uma empresa do setor têxtil**. Dissertação (Mestrado) – Universidade de Caxias do Sul, Programa de Pós-Graduação em Administração, 2008.

GUERRA, I. G. **Modelo de previsão da demanda para a Millagre Industria de Alimentos LTDA**. Trabalho de conclusão de curso – Universidade Federal de Sergipe, Centro de Ciências Sociais Aplicadas. São Cristovão – SE, 2019.

JÚNIOR, A. B. J.; OLIVEIRA, F. M.; PÁDUA, F. L. D.; MATIAS, M. A.; DAYRELL, V. M. Aplicação de métodos de previsão de demanda e desenvolvimento de ferramenta de revisão periódica em uma distribuidora de bebidas e bomboniere. **XXXVIII Encontro Nacional de Engenharia de Produção**, Maceió: ABEPRO, 2018.

JÚNIOR, A. S. M.; SILVA, D. L. Proposta de modelo de previsão de vendas para jornal. **XIII Simpósio de Excelência em Gestão e Tecnologia**, Resende: AEDB, 2016.

KRAJEWSKI, L. J.; RITSMAN, L. P.; MALHOTRA, M. K. **Administração de Produção e Operações**. 8ª. Ed. 3ª Reimpressão, São Paulo: Pearson Education do Brasil, 2012.

KOTLER, P.; KELLER, K. L. **Administração de Marketing**. 14ª ed São Paulo: Pearson Education do Brasil, 2012.

LEMOS, F. O. **Metodologia para seleção de métodos de previsão de demanda**. Dissertação de Mestrado - Universidade Federal do Rio Grande do Sul, Escola de Engenharia. Porto Alegre, 2006.

MARTINS, P. G.; LAUGENI, F. P. **Administração da Produção**. 3ª ed São Paulo: Saraiva, 2015.

MANCUZO, F. **Análise e previsão de demanda: Estudo de caso em uma empresa distribuidora de rolamentos**. Dissertação de Mestrado - Universidade Federal do Rio Grande do Sul, Escola de Engenharia. Porto Alegre, 2003.

MIRANDA, R. G. de; ANDRADE, G. J. P. O. de; GERBER, J. Z.; BORNIA, A. C. Método estruturado para o processo de planejamento da demanda nas organizações. **Revista ADMPG**, v. 4, n. 2, 17 jul. 2019.

MORETTIN, P. A.; TOLOI, C. M. **Análise de Séries Temporais**. 3ª. ed São Paulo: Edgard Blücher, 2018.

PANORAMA ILOS: **Planejamento da Demanda e S&OP nas empresas brasileiras**. 2015.

REIS, F. D. **Avaliação de modelos de previsão de vendas a partir da exploração de técnicas de análise de séries temporais, métodos causais e de redes neurais artificiais**. Dissertação de Mestrado - Universidade FUMEC, Faculdade de Ciências Empresariais, Gestão de Sistemas de Informação e Gestão do conhecimento. Belo Horizonte, 2014.

SANTOS, M.; CHAVES, M. B. M.; GOMES, C. F. S.; DIAS, F. C.; ABREU, V. V. S.; Pesquisa de um modelo de previsão de demanda para uma multinacional de produtos químicos do Rio de Janeiro. **VII Congresso de Sistemas LEAN**. Niterói, RJ: 2017.

SALAS-FIERRO, T. E.; SAUCEDO-MARTINEZ, J. A.; RODRIGUEZ-AGUILAR, R.; VELA-HARO, J. M. **Demand prediction using a soft-computing approach: a case study of automotive industry**. Applied Sciences, v10, n. 3, pg. 829, 2020.

SILVA, B. W. **Gestão de Estoques: Planejamento, Execução e Controle**. 2ª ed. João Monlevade: BWS Consultoria, 2019.

SILVA, F. R. **Previsão de demanda e planejamento comercial**. São Paulo: Editora Senac São Paulo, 2020.

SLACK N.; CHAMBERS S.; JOHNSTON R. **Administração da produção**. 3 ed. São Paulo: Editora Atlas, 2009.

SOREL, K.; GAO, S. **MIT Campus PPE Demand Planning**. 2021.

WERKEMA, M. C. C. **Design for Lean Six Sigma: Ferramentas básicas usadas nas etapas D e M do DMADV**. 2 ed Belo Horizonte: Editora GEN LTC, 2012.

ZAN, G. L. **Técnicas de previsão de demanda: um estudo de caso triplo com dados de vendas de materiais eletro-mecânicos.** GEPROS: Gestão da Produção, Operações e Sistemas – Ano 2, Bauru – SP, vol. 4, jul-set/07, p.95-106.