

RENAN DA SILVA BARROS

**Revisão dos modelos de previsão de demanda e controle de estoques em uma empresa
varejista**

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

SÃO PAULO

2021

RENAN DA SILVA BARROS

**Revisão dos modelos de previsão de demanda e controle de estoques em uma empresa
varejista**

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

Orientador: Prof. Dr. Marco Aurélio de Mesquita

SÃO PAULO

2021

Autorizo a reprodução e divulgação total ou parcial deste trabalho, por qualquer meio convencional ou eletrônico, para fins de estudo e pesquisa, desde que citada a fonte.

FICHA CATALOGRÁFICA

Barros, Renan da Silva.

Revisão dos modelos de previsão de demanda e controle de estoques em uma empresa varejista / R. D. S. Barros – São Paulo, 2021.

110 p.

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

1. Controle de Estoques 2. Previsão de Demanda 3. Setor de Varejo 4. Estoque de Segurança 5. Simulação I. Universidade de São Paulo. Escola Politécnica. Departamento de Engenharia de Produção II.t.

Aos meus pais, por todo o apoio e
oportunidades que propiciaram durante
minha vida.

AGRADECIMENTOS

Aos meus pais, por todo o suporte, carinho, ambição e geração de oportunidades que foram essenciais para a minha trajetória.

À minha irmã, por todo o carinho e motivação, principalmente nos momentos mais conturbados.

À minha cachorra Lola, por todo o amor e suporte emocional oferecido.

À Sabrina, pelo seu amor, apoio e companheirismo.

Aos meus professores do Colégio Rio Branco, que me tornaram um cidadão melhor além de me propiciarem as condições de almejar um grande futuro.

À Escola Politécnica da USP por todas as oportunidades de desenvolvimento intelectual, tanto de maneira teórica quanto prática, que permitiram meu amadurecimento e resiliência para enfrentar desafios.

À Poli Júnior e todos os membros com os quais tive contato durante meus 2 anos como membro, por toda a amizade, evolução técnica, profissional e pessoal e oportunidades de ingressar no mercado de trabalho.

Aos meus colegas de trabalho, por todo o conhecimento adquirido durante o período de estágio.

Ao professor Marco Aurélio de Mesquita por sua disposição e dedicação na orientação deste trabalho.

Provérbio Chinês

千里之行，始於足下

*A journey of a thousand miles
begins with a single step.*

RESUMO

O trabalho tem como objetivo revisar os modelos de previsão de demanda e controle de estoques utilizados em uma empresa varejista e propor um método alternativo com desempenho superior. A metodologia empregada foi a revisão e mapeamento de processos seguindo a notação BPMN, diagnóstico dos principais problemas e por fim simulações do modelo atual e de modelos alternativos. Foram testados 5 modelos de controle de estoques e 5 modelos de previsão de demanda, totalizando 25 experimentos de simulação. Cada experimento executou 50 réplicas para cada um dos 249 SKUs. Os modelos de controle de estoque consideram revisão periódica e diferenciam-se principalmente quanto ao método de definição do estoque de segurança. Para os modelos de previsão de demanda, foram testados tanto métodos univariados, como média móvel, Holt-Winters e SARIMA, tanto quanto métodos multivariados que modelam relações de causa-efeito, como Método dos Mínimos Quadrados e *Random Forest*. Os modelos multivariados são testados de maneira a tentar capturar o efeito na demanda provocado por eventos sazonais, como Natal e *Black Friday*, assim como preços, promoções e *stockouts*. Para os modelos que utilizam variáveis independentes, foram utilizados três métodos de seleção de variáveis: stepwise, LASSO e um terceiro método baseado no *Random Forest*. Os resultados das simulações foram avaliados de acordo com estoque médio e nível de serviço (*fill rate*) realizado. O melhor cenário resultou em um aumento de mais de 10% no *fill rate* realizado comparado com o cenário base, porém com um pequeno aumento de 3% nos níveis de estoque. Além do ganho financeiro e operacional, o controle de estoques mais eficiente também proporciona benefícios para a rotina de trabalho dos funcionários envolvidos com os processos de decisão sobre abastecimento.

Palavras-chave: Controle de Estoques. Previsão de Demanda. Setor de Varejo. Estoque de Segurança. Simulação

ABSTRACT

This paper aims to review both demand forecasting and inventory control models in a retail company and propose an alternative method which outperforms the current one. The methodology used was the review and mapping of processes according to the BPMN notation, diagnostic of the main problems and simulations to test the current and alternative models. Five inventory control models and 5 demand forecasting models were tested, totaling 25 simulation experiments. Fifty replications were done for each one of the 249 SKUs for each experiment. The built-in inventory control models considered periodic review and differ mainly in terms of the method of defining safety stock. For the demand forecast models, both univariate methods, such as moving average, Holt-Winters and SARIMA, as well as multivariate methods, such as Least Squares Method, Random Forest, were tested. The multivariate models are tested in order to try to capture the effect on demand caused by seasonal events such as Christmas and Black Friday, as well as prices, promotions and stockouts. For multivariate methods, three feature selection methods were used: stepwise, LASSO and third one based on Random Forest. Simulation results were evaluated according to average stock and performed service level (fill rate). The best scenario resulted in an increase of more than 10% in the performed fill rate compared to the baseline scenario but with a small increase of 3% in stock levels. In addition to the financial and operational gain, more efficient inventory control also provides benefits to the work routine of employees involved in supply decision processes.

Keywords: Inventory Control. Demand Forecasting. Retail. Safety Stock. Simulation

LISTA DE FIGURAS

Figura 1 – Cadeia de Suprimentos.....	17
Figura 2 – Hierarquia de categorização de produtos.	19
Figura 3 – Participação das categorias de 3 dígitos no faturamento de 2020.....	19
Figura 4 – Classificação ABC	24
Figura 5 - Comparação de modelos de controle de estoque com e sem perda de vendas	26
Figura 6 - Modelo $\langle s, Q \rangle$ de reposição de estoques	27
Figura 7 - Modelo $\langle S-1, S \rangle$ de reposição de estoques	29
Figura 8 - Modelo $\langle T, S \rangle$ de reposição de estoques.....	30
Figura 9 - Modelo $\langle T, s, S \rangle$ de reposição de estoques	31
Figura 10 - Representação gráfica dos componentes de uma série temporal.....	40
Figura 11 - Comparação de série estacionária com série não estacionária	41
Figura 12 - Componentes do modelo ARIMA	45
Figura 13 - Função de Autocorrelação Parcial (PACF)	46
Figura 14 - Estrutura de uma árvore de decisão	50
Figura 15 - Fluxograma da seleção <i>stepwise</i>	51
Figura 16 – Elementos da notação BPMN no software <i>Bizagi</i>	55
Figura 17 – Exemplo de utilização dos elementos <i>Pool</i> e <i>Lane</i>	56
Figura 18 - Exemplo de uso dos elementos Data Object e Fluxo.....	57
Figura 19 - Exemplo de utilização dos elementos Atividade e Subprocesso	58
Figura 20 - Diferentes tipos de atividade.....	58
Figura 21 - Exemplo de eventos de início e término de um processo	60
Figura 22 - Tipos de evento.....	60
Figura 23 - Exemplo de aplicação de um <i>gateway</i>	62
Figura 24 - Tipos de Gateway	62
Figura 25 - Etapas de um projeto de simulação.....	65
Figura 26 – Série histórica de vendas agregadas dos SKUs.....	87
Figura 27 – Decomposição da série temporal das vendas agregadas dos SKUs.....	88
Figura 28 – Pseudocódigo do algoritmo Holt-Winters.....	89
Figura 29 – Pseudocódigo do algoritmo SARIMA	90
Figura 30 – Exemplo de otimização de parâmetros da função <i>auto_arima()</i>	91
Figura 31 – Pseudocódigo do algoritmo MMQ.....	95

Figura 32 – Pseudocódigo do algoritmo de regressão por <i>Random Forest</i>	96
---	----

LISTA DE TABELAS

Tabela 1 – Categoria de produtos na granularidade de 3 dígitos.....	18
Tabela 2 - Classificação dos modelos de reposição de estoques	26
Tabela 3 - Possíveis abordagens para lidar com <i>stockouts</i> em séries de vendas	39
Tabela 4 - Métodos de suavização exponencial	43
Tabela 5 - Descrição dos tipos de atividades.....	59
Tabela 6 - Descrição dos tipos de evento	61
Tabela 7 - Descrição dos tipos de <i>gateway</i>	63
Tabela 8 - Vantagens e desvantagens do uso de simulação	64
Tabela 9 - Diagnóstico dos principais problemas processo atual de compras	71
Tabela 10 - Diagnóstico dos principais problemas do processo atual de distribuição	73
Tabela 11 – Comparação do cenário base com dados reais	79
Tabela 12 – Descrição do escopo da simulação	86
Tabela 13 – Variáveis testadas nos modelos multivariados	91
Tabela 14 – Variáveis retornadas pelos métodos de seleção de variáveis.....	93
Tabela 15 – Desempenho dos modelos de previsão	97
Tabela 16 – Resultados dos cenários simulados.....	99

LISTA DE ABREVIATURAS E SIGLAS

AIC - *Akaike Information Criterion*

ANN – *Artificial Neural Networks*

ARIMA – *AutoRegressive Integrated Moving Average*

BPMN – *Business Process Model and Notation*

CD – Centro de Distribuição

CSL – *Cycle Service Level*

DNN – *Deep Neural Networks*

ES – Estoque de Segurança

FR – *Fill Rate*

LASSO - *Least Absolute Shrinkage and Selection Operator*

MAE: *Mean Absolute Error*

MASE: *Mean Absolute Scaled Error*

MAPE: *Mean Absolute Percentage Error*

ME: *Mean Error*

MMQ – Método dos Mínimos Quadrados

MQO – Mínimos Quadrados Ordinários

MSE: *Mean Squared Error*

OLS – *Ordinary Least Squares*

RMSE: *Root Mean Squared Error*

sMAPE: *Symetric Mean Absolute Percentage Error*

SARIMA – *Seasonal AutoRegressive Integrated Moving Average*

SARIMAX – *Seasonal AutoRegressive Integrated Moving Average with Exogenous Regressors*

SAP - Sistemas, Aplicativos e Produtos para Processamento de Dados

SES – Suavização Exponencial Simples

SKU – *Stock Keeping Units*

SVR – *Support Vector Regression*

VBA - *Visual Basic for Applications*

wMAPE – *Weighed Mean Absolute Percentage Error*

SUMÁRIO

1	INTRODUÇÃO	15
1.1	O SETOR DE VAREJO	15
1.2	CARACTERIZAÇÃO DA EMPRESA.....	15
1.2.1	Cadeia de Suprimentos	16
1.2.2	Produtos e Categorias	17
1.3	FORMULAÇÃO DO PROBLEMA.....	20
1.3.1	Controle do Estoque Central.....	20
1.3.2	Controle do Estoque nas Lojas	21
1.4	OBJETIVOS.....	22
1.5	ESTRUTURA DO TRABALHO	22
2	REVISÃO BIBLIOGRÁFICA	23
2.1	CONTROLE DE ESTOQUES	23
2.1.1	Importância da Gestão de Estoques no Varejo	23
2.1.2	Modelos de Reposição de Estoques.....	24
2.1.3	Indicadores de Desempenho na Gestão de Estoques	34
2.2	PREVISÃO DE DEMANDA	37
2.2.1	Contexto da Previsão de Demanda no Varejo	37
2.2.2	Métodos Univariados de Previsão de Demanda por Séries Temporais.....	40
2.2.3	Métodos Causais de Previsão de Demanda	48
2.2.4	Seleção de Variáveis em Modelos Causais de Previsão de Demanda.....	50
2.2.5	Métricas de Mensuração de Erros.....	52
2.3	MAPEAMENTO DE PROCESSOS	55
2.4	SIMULAÇÃO	63
3	METODOLOGIA.....	66
3.1	REVISÃO DOS PROCESSOS DA EMPRESA	66

3.2	PROJETO DE SIMULAÇÃO	66
4	DESENVOLVIMENTO.....	69
4.1	REVISÃO DOS PROCESSOS DA EMPRESA	69
4.1.1	Revisão do processo de compras	69
4.1.2	Revisão do processo de abastecimento das lojas	73
4.1.3	Revisão dos indicadores utilizados para avaliação do estoque.....	74
4.2	MODELAGEM E SIMULAÇÃO	75
4.2.1	Modelos de controle de estoques.....	75
4.2.2	Coleta de dados e restrição do escopo	82
4.2.3	Modelos de previsão de demanda.....	87
4.3	RESULTADOS E DISCUSSÃO.....	96
4.3.1	Resultados dos modelos de previsão	97
4.3.2	Resultados das simulações de controle de estoques	98
4.3.3	Revisão dos processos	101
5	CONCLUSÕES.....	102
5.1	SÍNTESE	102
5.2	LIMITAÇÕES	103
5.3	DESDOBRAMENTOS E OPORTUNIDADES	104
	REFERÊNCIAS.....	105
	APÊNDICE A – Fluxograma do Processo de Compras.....	108
	APÊNDICE B – Fluxograma do Processo de Abastecimento de Lojas.....	110

1 INTRODUÇÃO

Neste capítulo, apresenta-se o contexto do problema de controle de estoques e a empresa varejista em estudo. Por questões de confidencialidade, o nome da organização será omitido e ao longo do trabalho será denominada apenas como “Empresa”. Após a caracterização da Empresa, serão definidos o problema e os objetivos, assim como a estrutura deste trabalho.

1.1 O SETOR DE VAREJO

O setor de varejo é marcado por ser um ambiente muito competitivo, normalmente envolvendo margens de lucro estreitas, enquanto a tomada de boas decisões a respeito da reposição de estoques é um importante direcionador nos resultados da empresa. Desse modo, a previsão de venda que embasa as decisões de reposição de estoques se torna um processo chave para ser bem-sucedido nesse setor. Caso a previsão não seja precisa, podem ocorrer situações de escassez ou excesso de estoques, impactando diretamente na lucratividade.

O efeito de previsões de demanda imprecisas não se resume somente a lucratividade, como também à qualidade de atendimento do consumidor. Quando os consumidores se deparam com a escassez de um produto desejado, eles podem procurar o produto em um concorrente, resultando em uma venda perdida e risco de perder um cliente. Para evitar cenários de escassez de produtos, muitos varejistas acabam aumentando indevidamente os níveis de estoque e comprometendo o resultado da operação.

As vendas dos produtos podem ser direcionadas de acordo com diversas variáveis internas e externas à empresa, como foi o caso do cenário pandêmico gerado pela COVID-19. Motivos como estes tornam desafiador o processo de gerar previsões de demanda assertivas no setor varejista.

1.2 CARACTERIZAÇÃO DA EMPRESA

A Empresa, sediada em Manaus, foi fundada em 1942 como uma firma de representações comerciais. Iniciou comercializando medicamentos e posteriormente cereais, cimento e eletrodomésticos. Tornou-se uma empresa moderna e ágil, destacando-se como líder regional em quase todos os segmentos em que atua: eletroeletrônicos, eletrodomésticos,

móveis, autoatendimento, produtos automotivos, farmacêuticos, entre outros. Há vários anos seguidos é apontada em pesquisas de mercado e pesquisas de marca como a Loja de Departamentos mais lembrada pela população de Manaus.

Em 2016, a Empresa retomou o ramo inicial do grupo, inaugurando seu mais novo empreendimento, a primeira drogaria. Internamente, o segmento de drogarias da Empresa é tratado como uma divisão isolada, fora da sua área *core*. Por conta dessa divisão de drogarias ser mais recente, ainda está passando por constantes expansões. Em 2020, o faturamento anual proveniente das farmácias representou apenas cerca de 3% do faturamento total da Empresa. Desse modo, optou-se por não incluir o varejo farmacêutico no escopo abordado neste trabalho tendo em vista suas particularidades que teriam que ser contornadas de maneira diferente do varejo não farmacêutico. A denominação “Empresa” passa a se referir apenas ao varejo não farmacêutico.

Mais recentemente, no final de 2020, a Empresa inaugurou o primeiro supermercado de sua rede. Essa expansão foi decorrente de uma estratégia de aumentar as oportunidades de atuação diante de um cenário de pandemia onde as lojas físicas permaneceram fechadas ou funcionando com restrições por alguns meses, enquanto supermercados funcionavam sem restrição.

1.2.1 Cadeia de Suprimentos


A Empresa possui atualmente 30 lojas físicas, 1 supermercado, 1 loja online e 3 centros de distribuição. Estas instalações estão distribuídas nos estados do Amazonas, Rondônia, Roraima e Acre, como pode ser observado na Figura 1. Observa-se que a Empresa atua unicamente na região Norte do país e se beneficia da sua competência em superar os desafios logísticos complexos que acabam atuando como barreiras de entrada para competidores vindos de outras regiões do país.

As compras são feitas majoritariamente para o centro de distribuição do Amazonas, que é o CD com maior capacidade da cadeia, responsável por suprir as demandas das lojas físicas, das vendas online e dos centros de distribuição menores. Entretanto, existem outros fluxos possíveis representados na Figura 1.

O único modal utilizado dentro do estado do Amazonas e de Roraima é o rodoviário, devido à proximidade das unidades. Todavia, para a distribuição de mercadorias para os estados

de Rondônia e para o Acre, podem ser utilizados outros modais como o aéreo e o rodo fluvial. O modal aéreo traz como benefício a redução do *lead time*, em troca de maiores custos de transporte. Já o modal rodo fluvial proporciona redução de custo de transporte em troca de *lead times* mais longos.

Figura 1 – Cadeia de Suprimentos



Fonte: Elaboração própria.

1.2.2 Produtos e Categorias

A Empresa possui um ramo bem diversificado de produtos em seu portfólio. Atualmente conta com cerca de 15.000 *Stock Keeping Units* (SKUs) em estoque no Centro de Distribuição (CD) ou nas lojas, sendo que aproximadamente 9.000 são SKUs ativos. Os itens ativos correspondem aos produtos que podem ser comprados dos fornecedores. Os inativos, por sua vez, são os SKUs que não serão mais comprados, mas podem continuar sendo distribuídos do CD para as lojas até o término do seu estoque.

A categorização de seus produtos ocorre hierarquicamente em 3 granularidades diferentes:

- **Grupo 3:** é um código de 3 dígitos que descreve a categoria do produto de uma maneira mais abrangente.
- **Grupo 6:** é uma subdivisão do Grupo 3. Trata-se de um código de 6 dígitos, nos quais os 3 primeiros são idênticos ao do Grupo 3.

- **Grupo 9:** é uma subdivisão do Grupo 6. Trata-se de um código de 9 dígitos, nos quais os 6 primeiros são idênticos ao do Grupo 6.


Para melhor entendimento do portfólio de produtos da Empresa, a Tabela 1 exibe todas as categorias na granularidade do Grupo 3 e suas respectivas descrições. Já a Figura 2 demonstra um exemplo da hierarquia de categorizações.

Tabela 1 – Categoria de produtos na granularidade de 3 dígitos

Grupo 3	Descrição do Grupo
101	ARTIGOS INFANTIS
102	ÁUDIO
103	IMPORTADO
104	BICICLETA
105	BRINQUEDOS
107	CAMA, MESA E BANHO
108	DRONES
109	CAMAS, COLCHÕES E TRAVESSEIROS
110	SAÚDE E BELEZA
111	ELETROPORTÁTEIS
112	IMPORTADO
113	FAÇA VOCÊ MESMO
114	INFORMÁTICA
115	INST MUSICAL E CALCULADORAS
116	LAZER ESPORTE
117	LINHA BRANCA
118	MÁQS, MOTORES E PEÇAS
119	AUTOMOTIVO
120	MÓVEIS
123	PRESENTE
125	RELÓGIOS
126	TELEFONIA
127	UTILIDADE DOMÉSTICA
128	MATERIAL ESCOLAR
129	VIAGEM
130	VÍDEO
131	GAMES
132	SMART HOME
133	PET SHOP
134	CONVENIÊNCIA
135	MATERIAL DE CONSTRUÇÃO

Fonte: Elaboração própria.


Figura 2 – Hierarquia de categorização de produtos.



Fonte: Elaboração própria.

A Figura 3 apresenta um diagrama de Pareto com a participação de cada categoria no faturamento total obtido durante o ano de 2020.

Figura 3 – Participação das categorias de 3 dígitos no faturamento de 2020



Fonte: Elaboração própria.

A lei de Pareto, também conhecida como princípio 80-20, afirma que, para muitos fenômenos, 80% dos efeitos advêm de 20% das causas. Esse princípio também pode ser observado na Figura 3, na qual poucas categorias concentram a maior parte do faturamento. Por exemplo, Telefonia e Linha Branca, que são as duas primeiras categorias com maior faturamento respectivamente, foram responsáveis por quase 60% do faturamento total de 2020. Já as 6 categorias com maior faturamento representam aproximadamente 80% do faturamento total, enquanto a representação do total de categorias é de aproximadamente 20%.

1.3 FORMULAÇÃO DO PROBLEMA

Conforme mencionado no tópico 1.1, o controle de estoques exerce um papel fundamental nos resultados financeiros dos varejistas. Embora existam modelos de controle de estoques que não utilizam previsão de demanda (reativos), os modelos baseados em previsão tendem a dar melhor resultados e por isso este estudo irá explorar esses tipos de modelos. Desse modo, a acurácia da previsão de demanda direciona os resultados de controle de estoques, tornando-se também um processo essencial.

O controle de estoque de uma variedade grande de itens, como é o caso da Empresa, torna-se complexo e exige uma sistematização dos processos de planejamento para tornar o controle mais robusto e eficaz.

1.3.1 Controle do Estoque Central

A Empresa utiliza um modelo de controle de estoques bem simplificado para calcular as necessidades de pedidos de compra para o CD de Manaus. Essas necessidades são levantadas a partir da previsão de demanda, descontando os atuais valores de estoque no CD e os pedidos a receber dos fornecedores. Entretanto, os dados de *lead time* dos fornecedores e o período de revisão dos produtos (os parâmetros T e L do modelo clássico de controle de estoques com revisão periódica) não são levados em consideração no horizonte de tempo da previsão de demanda. Para a grande maioria dos SKUs, o período de revisão da necessidade de compra é semanal.

A previsão de demanda é calculada de acordo com uma média móvel das vendas mensais dos últimos 5 meses, descontando-se os meses de maior e menor venda do produto.

Esse método de remover os meses de pico e de vale das vendas é uma tentativa de reduzir o impacto da sazonalidade na previsão de vendas. Após obter a média móvel na granularidade de venda mensal, ela é dividida por 30 para se obter uma venda média diária e, em seguida, multiplicada pelo horizonte de tempo da previsão, que usualmente é um número pré-determinado de dias, que varia de acordo com a classificação ABC do SKU.

O modelo de controle de estoques, considerando um horizonte de previsão de vendas fixo para todos os produtos, traz problemas de escassez quando o *lead time* do fornecedor é superior a esse horizonte. O contrário acontece quando o *lead time* do fornecedor é inferior a tal horizonte, gerando excesso de estoque. Este horizonte é definido com base no conhecimento, experiência e intuição dos gestores, de maneira a incluir também um estoque de segurança.

Além disso, o método de média móvel utilizado para previsão de demanda, apesar de simplificado, exige muito tempo de dedicação do time responsável pelas compras, principalmente em momentos que antecedem datas especiais como *Black Friday*, Natal, entre outras. Isso acontece porque o método não apresenta bons resultados para produtos com sazonalidade na demanda, requerendo que os gestores determinem as quantidades a serem compradas com base em suas experiências e intuições.

1.3.2 Controle do Estoque nas Lojas

O processo denominado “distribuição” refere-se ao envio de produtos dos CDs para as lojas. A decisão sobre a quantidade de cada produto a ser entregue para uma determinada loja é feita com base numa grade de referência de valores mínimos e máximos de estoque. Diariamente, os estoques dos produtos nas lojas são comparados com seus respectivos valores de estoque mínimo da grade de referência. Para os produtos que apresentam um nível de estoque inferior ao ponto de ressuprimento da grade, emite-se uma ordem de transferência para o CD que, por sua vez, providencia a distribuição dos produtos para as lojas em quantidades suficientes para que estas atinjam o valor de estoque máximo da grade de referência.

A dificuldade deste processo encontra-se na determinação dos valores de estoques mínimo e máximo, que são arbitrários e não há muito embasamento para alteração desses valores ao longo do tempo. A falta de calibração adequada destes parâmetros acaba levando a cenários de escassez ou excesso de produtos nas lojas.

1.4 OBJETIVOS

O objetivo do trabalho é propor um novo modelo de previsão de demanda e controle de estoques (central e das lojas) para melhorar o controle de estoques da Empresa de acordo com os indicadores de desempenho apropriados. A hipótese seguida por este estudo é a de que os resultados da operação podem ser melhorias com a utilização de um modelo mais robusto e assertivo de previsão de demanda, aliado à correta utilização dos parâmetros tradicionais de revisão periódica e metodologias mais embasadas de determinação de estoque de segurança.

Este trabalho é parte de um serviço de consultoria, de modo que os novos modelos e processos estudados são primeiro avaliados por simulação para posterior recomendação de implantação pela Empresa.

1.5 ESTRUTURA DO TRABALHO

Neste capítulo foi apresentada a Empresa envolvida neste projeto de formatura, bem como a formulação do problema e dos objetivos.

O capítulo 2 traz uma revisão teórica sobre métodos de controle de estoques e previsão de demanda. O capítulo 3 apresenta a metodologia empregada no desenvolvimento do trabalho. O capítulo 4 apresenta o desenvolvimento do trabalho e a discussão de resultados. Por fim, o capítulo 5 conclui o trabalho com uma síntese, as recomendações para implementação dos novos modelos e processos, as limitações e os desdobramentos do estudo.

2 REVISÃO BIBLIOGRÁFICA

Neste capítulo é apresentado um referencial teórico a respeito dos principais assuntos que envolvem o presente estudo: controle de estoques e previsão de demanda.

2.1 CONTROLE DE ESTOQUES

2.1.1 Importância da Gestão de Estoques no Varejo

O gerenciamento de uma cadeia de suprimentos é um conjunto de abordagens utilizado para integrar de maneira eficiente os fornecedores, fabricantes, armazéns e lojas, de modo que as mercadorias sejam produzidas e distribuídas em quantidades corretas, nas localizações corretas e no tempo correto, para minimizar os custos do sistema sem comprometer os níveis de serviço requeridos (Simchi-Levi *et al.*, 2008). A gestão da cadeia de suprimentos é uma direcionadora chave do sucesso de negócios em um mundo globalizado. O modo como as empresas gerenciam suas redes de suprimentos e tomam decisões sobre como alocar seus recursos é crucial para a lucratividade no longo prazo e o crescimento sustentável do negócio (Kella & Agrogiannis, 2016).

Em busca de eficiência operacional em um ambiente de negócios cada vez mais adverso e competitivo, as empresas começaram a olhar para a reconfiguração de suas cadeias de abastecimento, a fim de obter economias de escala e melhorar os fluxos de caixa de suas próprias operações (Steeman, 2014).


O gerenciamento de estoque é um dos principais direcionadores de eficiência de qualquer operação (Arnold, 2016). O aumento da competitividade e a necessidade de atender aos requisitos dos clientes desencadearam um aumento na incerteza dentro das organizações (Gupta & Maranas, 2003). Estoques de segurança são considerados como artifícios adequados para prevenir escassez de produtos (Eruguz *et al.*, 2016) e lidar com as variabilidades da demanda e do abastecimento (Whybark & Williams, 1976; Boulaksil 2016). Estoques de segurança são definidos em função do nível de serviço, da incerteza da demanda, do *lead time* do ciclo de reposição e da incerteza deste *lead time* (Chopra *et al.*, 2004).

Aumentar os níveis de estoque de segurança leva a um aumento da disponibilidade do produto para vendas, porém também leva a um aumento nos custos de armazenagem. A

determinação dos níveis ideais de estoque é um processo importante e desafiador para uma empresa (Kella & Agrogiannis, 2016).

Um método comum para auxiliar a definição das políticas de estoque para cada SKU em um cenário de múltiplos itens é a classificação ABC (ARNOLD, 2008). A essência dessa classificação segue a lei do Pareto já apresentada na seção 1.2.2. Desse modo, 20% dos itens representam 80% do faturamento, sendo classificados como itens A; 30% dos itens representam 15% do faturamento, sendo classificados como itens B; os 50% restantes dos itens representam apenas 5% do faturamento e são classificados como itens C. A Figura 4 ilustra a classificação.

Figura 4 – Classificação ABC



Fonte: Adaptado de ARNOLD (2008)

2.1.2 Modelos de Reposição de Estoques

Um estudo conduzido por Corsten *et al.* (2002) revela que apenas 15% dos consumidores que se deparam com uma situação de escassez de um produto irão esperar até que ele esteja disponível nas prateleiras novamente, enquanto os outros 85% irão comprar um produto diferente (45%) ou procurar o produto desejado em algum outro lugar (31%) ou até mesmo deixar de comprar o produto (9%). Esses resultados demonstram que em cenários de escassez, a maior parte da demanda não atendida pode ser considerada como perdida.

Entretanto, boa parte dos modelos de controle de estoque da literatura assumem que a demanda pode ser postergada, ou seja, o cliente irá esperar até o momento da disponibilidade

do produto para fazer a compra. Esses modelos são comumente aplicados em indústrias, porém não são bem representativos do cenário do setor varejista. Quando modelos de controle de estoque com perda de venda são aproximados por modelos com adiamento da demanda, a variação entre custos de estoque previstos e realizados podem ser de até 30% (Zipkin, 2008).

Segundo Bijvank *et al.* (2011), mesmo que estudos acerca de modelos de controle de estoques com perda de venda começaram desde a década de 1960, não existem muitas aplicações práticas que utilizem modelos com perda de venda. Isso ocorre porque esse tipo de modelo de controle de estoques é mais difícil de se analisar e calcular em modelos de otimização, tendo em vista que não se consegue determinar uma política garantidamente ótima. Quando a demanda é perdida ao invés de postergada, a posição de estoque não decresce em caso de escassez do produto, ou seja, a posição de estoque não pode ser considerada como negativa.

Ainda de acordo com Bijvank *et al.* (2011), o processo de reposição de estoques pode ser caracterizado por: um período de revisão, determinação da quantidade do pedido, custos do pedido e função objetivo. Abaixo encontram-se alguns conceitos e denominações usados para se discutir os modelos de estoque:

- **Lead Time:** trata-se do período L necessário para se receber o estoque após realizar um pedido de reposição.
- **Posição de Estoque:** representa a quantidade de estoque atualmente disponível mais a quantidade de estoque em trânsito, ou seja, de pedidos feitos anteriormente que ainda não foram entregues.
- **Período de Revisão:** o estoque pode ser monitorado de maneira contínua (revisão contínua) ou pode ser monitorado em um período regular de intervalos de tamanho T (revisão periódica).
- **Ponto de Ressuprimento:** a decisão entre fazer um pedido ou não num determinado instante de revisão se baseia na definição de um ponto de ressuprimento s . Esse ponto s representa a posição de estoque a partir da qual será feito um pedido caso a posição de estoque atual seja igual ou inferior a s .
- **Quantidade do Pedido:** Trata-se da quantidade Q de unidades a serem pedidas, que pode ser um valor fixo ou variável. O tipo de política de reposição com quantidades de pedido variáveis é chamado de política *order-up-to*, de maneira que Q seja a quantidade em unidades necessária para se atingir um determinado nível de estoque S .

- **Custo do Pedido:** Pode ser que exista algum custo fixo no processo de fazer um pedido. Em um cenário sem custos de pedido, não há incentivos para deixar de fazer um pedido a cada instante de revisão no caso de uma política onde a quantidade Q não é fixa. Consequentemente, nesses casos, o ponto de ressuprimento s não exerce um papel significativo no modelo de controle de estoques ($s = S - 1$).


A Tabela 2 exibe as notações para os seis tipos de políticas de reposição mais comumente aplicadas na literatura. A Figura 5 ilustra a comparação de um modelo de controle de estoques de revisão periódica considerando perda de venda, com um modelo onde a demanda pode ser postergada. Em seguida, serão explicados mais detalhadamente os principais modelos da Tabela 2.

Tabela 2 - Classificação dos modelos de reposição de estoques

		PERÍODO DE REVISÃO	
		Revisão Contínua	Revisão Periódica
TAMANHO DO PEDIDO	Fixo	(s, Q)	(T, s, Q)
	Variável	Sem Custo Fixo: $(S - 1, S)$	Sem Custo Fixo: (T, S)
		Com Custo Fixo: (s, S)	Com Custo Fixo: (T, s, S)

Fonte: Adaptado de Bijvank et al. (2011)

Figura 5 - Comparação de modelos de controle de estoque com e sem perda de vendas




Fonte: Adaptado de Bijvank et al (2011)

Revisão Contínua com Pedido Fixo $\langle s, Q \rangle$

Esse modelo de controle de estoques opera de modo que um novo pedido de Q unidades é feito imediatamente assim que a posição de estoque atinge um nível abaixo do ponto de ressuprimento s . O processo está ilustrado na Figura 6.

Figura 6 - Modelo $\langle s, Q \rangle$ de reposição de estoques



Fonte: Adaptado de Biazzi (2019)

A quantidade Q pode ser calculada de acordo com a tradicional fórmula do modelo do Lote Econômico:

$$Q = \sqrt{\frac{2 \cdot C_p \cdot D}{C_a}} \quad (1)$$

Onde:

C_p = Custo unitário do pedido (R\$/pedido)

C_a = Custo unitário de armazenagem (R\$/unidade/período)

D = Demanda média no período (unidades/período)

Assumindo que a demanda siga uma distribuição normal, que é a distribuição mais tradicionalmente utilizada na literatura (Gonçalves *et al.*, 2020), o ponto de ressuprimento s

pode ser calculado por meio da demanda média durante o lead time mais um estoque de segurança, como indica a Equação 2.

$$s = D * L + ES \quad (2)$$

$$ES = z * \sigma_D * \sqrt{L} \quad (3)$$

Onde:

D = Demanda média no período

L = *Lead Time*

ES = Estoque de segurança

z = Coeficiente de segurança associado à curva normal de probabilidade

σ_D = Desvio padrão da demanda média no período

Em caso de *lead time* probabilístico, se L e D forem assumidas como variáveis aleatórias independentes, a equação do estoque de segurança (3) pode ser reescrita como:

$$ES = z * \sqrt{L * \sigma_D^2 + (\sigma_L * D)^2} \quad (4)$$

Onde:

σ_L = Desvio padrão do *lead time*

L = *lead time* médio

Gonçalves et al. (2020) ainda relatam uma abordagem diferente na literatura para definição de estoque de segurança com base na variabilidade dos erros da previsão da demanda ao invés de utilizar a variabilidade da demanda em si. Neste caso, a fórmula do ES é calculada por meio da equação (5), onde σ_F representa o desvio padrão dos erros de previsão para um respectivo *lead time* L, tipicamente assumido como determinístico e conhecido. Mais adiante ainda será discutido o modelo de controle de estoques quando a demanda é obtida por meio de uma previsão de demanda.

$$ES = z * \sigma_F \quad (5)$$


Quando as distribuições de demanda não seguem a premissa da aderência à distribuição normal, pode-se adotar alternativamente a equação (6), onde $Q_L(\alpha)$ representa o quantil da distribuição de erros de previsão durante o *lead time*.

$$ES = Q_L(\alpha) \quad (6)$$

Estoque Base $\langle S - 1, S \rangle$

Esta política de reposição permite fazer pedidos de tamanhos variados e não considera um custo fixo por pedido. Toda vez em que há uma demanda do consumidor atendida, imediatamente se faz um pedido de reposição para restaurar o valor do estoque ao valor do estoque base S . Este modelo pode ser vantajoso para itens com alto custo de falta e demanda média pequena, por exemplo, materiais de manutenção. A Figura 7 ilustra o processo de reposição adotando este modelo.

Figura 7 - Modelo $\langle S-1, S \rangle$ de reposição de estoques




Fonte: Adaptado de Biazzi (2019)

Revisão Periódica com Pedido Variável sem Custo Fixo $\langle T, S \rangle$

O modelo de revisão periódica monitora o nível do estoque em intervalos regulares. No momento da revisão, é ordenada uma quantidade suficiente para repor o estoque ao nível máximo S . Desse modo é permitido variar a quantidade do pedido, diferentemente de um modelo $\langle T, Q \rangle$. A Figura 8 ilustra o funcionamento do modelo.

Figura 8 - Modelo $\langle T, S \rangle$ de reposição de estoques



Fonte: Adaptado de Biazzi (2019)

As empresas que adotam este modelo podem optar por determinar o mesmo período R para um mesmo grupo de itens, por exemplo, itens de um mesmo fornecedor ou de uma mesma categoria, com o objetivo de facilitar processos de compra, transporte e pagamento. Lustosa *et al.* (2008) recomendam utilizar a regra 2^k , na qual os valores de T de cada item são arredondados na forma 2^k períodos (e.g. semana), onde k assume valores inteiros.

Apesar dos benefícios proporcionados por este modelo, Lustosa *et al.* (2008) também relatam que elevações repentinas na demanda podem ocasionar a escassez de estoque. Isso torna o modelo mais propenso a rupturas e por consequência acaba exigindo estoques de segurança maiores que em outros modelos.

O estoque máximo S pode ser calculado pela soma da demanda média durante o período do ciclo de reposição ($T + L$) adicionado de um estoque de segurança (ES). A fórmula do cálculo de S pode ser vista na equação (7), enquanto as fórmulas para cálculo de estoque de

segurança são análogas às apresentadas nas equações [3-6], com a diferença de que o período que era considerado apenas pelo *lead time* L na revisão contínua passa a ser $T + L$ na revisão periódica.


$$S = D * (T + L) + ES \quad (7)$$

Revisão Periódica com Pedido Variável com Custo Fixo $\langle T, s, S \rangle$

De acordo com Nahmias *et al.* (2009), o modelo de revisão contínua $\langle s, Q \rangle$ muitas vezes pode ser difícil de ser implementado na prática. Isso ocorre porque nem sempre é possível de se colocar um pedido de reposição exatamente quando o estoque atinge o ponto de ressuprimento s . Desse modo, o modelo de revisão periódica $\langle T, s, S \rangle$ surge como alternativa.

Essa política é uma variação do modelo de revisão periódica $\langle T, S \rangle$ apresentado anteriormente, com a diferença de que no instante de revisão T , só será feito um pedido caso o nível de estoque esteja inferior ao ponto de pedido s . A Figura 9 ilustra este processo.

Figura 9 - Modelo $\langle T, s, S \rangle$ de reposição de estoques



Fonte: Adaptado de Biazzi (2019)

Entretanto, os cálculos dos valores ótimos dos parâmetros T , s e S não são facilmente obtidos. Garcia *et al.* (2006) relatam que uma maneira de se obter um valor aproximado é por métodos de simulação enquanto Nahmias *et al.* (2009) sugerem como aproximação os cálculos de acordo com a política $\langle s, Q \rangle$, no qual o valor do parâmetro s seria mantido e o parâmetro S equivaleria a soma dos parâmetros s e Q .

Reposição Periódica baseada em Previsão de Demanda

Até o momento, os modelos apresentados podem ser denominados como reativos, dado que eles reagem à demanda realizada a partir de parâmetros predeterminados no momento da decisão. Alternativamente, pode-se adotar um modelo onde o cálculo da necessidade de compra é fundamentado por meio de uma previsão de demanda, ou seja, o modelo tenta antecipar o comportamento do sistema ao invés de apenas reagir.

A preferência pelo uso de modelos de previsão de demanda na tomada de decisão de reposição de estoques ocorre principalmente em situações em que a demanda apresenta fortes características de tendência e sazonalidade. Consequentemente, para se obter um bom desempenho na reposição de estoques, é necessário obter um modelo de previsão com um bom nível de precisão, o que pode se tornar uma barreira de utilização em organizações que não dominam as técnicas de previsão (Lutosa *et al.*, 2008).

Uma possível abordagem é combinar a revisão periódica com os *inputs* fornecidos pela previsão da demanda, desse modo, ao invés de se calcular um parâmetro de estoque máximo, calcula-se a necessidade estimada para atender o próximo período, também chamado de ciclo de reposição. Essa necessidade pode ser calculada em função da atual posição de estoque e da previsão de demanda até a próxima reposição ($T + L$), acrescida de um estoque de segurança (ES), como indica a equação (8).

$$Q = F(T + L) + ES - P_{atual} \quad (8)$$

Onde:

Q = Quantidade de pedido

$F(T+L)$ = Previsão de demanda até a próxima reposição

P_{atual} = Posição de estoque atual (em mãos e em trânsito)

De maneira similar à equação (3), Silver (1998) propõe um método para o cálculo do estoque de segurança com base na variabilidade dos erros da previsão, como indica a equação (9). Esta é uma abordagem interessante dado que tende reduzir a dimensão do estoque de segurança em comparação ao método em que o ES é dimensionado pela variabilidade da demanda em si, assumindo a premissa de que a previsão possui uma acuracidade melhor do que simplesmente assumir a média da demanda.

$$ES = k * \sigma_{T+L} \quad (9)$$

Onde:

k = fator de segurança associado aos erros de previsão

σ_{T+L} = desvio padrão dos erros de previsão no período de $T + L$

Comparação de abordagens para determinação do estoque de segurança

Um método comum usado por empresas para calcular o estoque de segurança é o número de dias multiplicado pela demanda média diária, sendo que esse número de dias é um parâmetro estimado para representar uma margem de tempo de segurança no processo de reposição de estoques (Jonsson *et al.*, 2019). Essa afirmação corrobora com o caso estudado neste trabalho, onde a Empresa adota um processo similar também de caráter simplista. Alternativamente, ao invés de se multiplicar o número de dias pela demanda média diária, pode-se incluir estes dias no período do ciclo de reposição utilizado em modelos de revisão periódica alimentados por previsão de demanda.

De acordo com Silver *et al.* (1998), aproximadamente 80% das empresas dos Estados Unidos utilizavam o método de dias de estoque ou algum outro método similar de caráter simplista para o cálculo de estoques de segurança. Um estudo na Suécia indica que este método ainda é muito comum, constatando que cerca de 48% das médias e grandes empresas ainda o utilizam (Jonsson *et al.*, 2016).

Ainda segundo Jonsson *et al.* (2019), o método de dias de estoque pode ser considerado como o método mais aplicado na prática pelas empresas. Dentre os que são também amplamente utilizados na prática, o mais abordado na literatura é o método de determinação de estoque de segurança com base em um fator calculado a partir de um *fill rate* (FR) desejado. O *cycle service level* (CSL) acaba sendo preterido pelo FR muitas vezes pelo motivo de não ser uma métrica muito relevante do ponto de vista do consumidor (Lewis, 1997). Além disso, abordagens de otimização por minimização de custos foram relatadas como pouco utilizadas na prática devido à dificuldade de se estimar com precisão os custos de escassez, também chamados de custo da falta, assim como custos de estocagem. Os conceitos de *fill rate* e *cycle service level* são discutidos na seção seguinte sobre indicadores de desempenho da gestão de estoques.

Ao comparar a performance dos dois métodos citados como mais utilizados, Jonsson *et al.* (2019) ainda ressaltam que se deve levar em consideração que muitas vezes as premissas geralmente assumidas no método baseado em um FR não são atendidas na prática, levando a *fill rates* realizados diferentes do desejado. Por exemplo, muitas vezes a demanda real não é aderente à distribuição teórica de probabilidade utilizada para modelar a demanda para os cálculos do estoque de segurança. Por fim, os autores relatam que pela falta de relações analíticas entre os dois métodos comparados, a simulação baseada em eventos discretos é a única metodologia possível para tal.

2.1.3 Indicadores de Desempenho na Gestão de Estoques

De maneira a mensurar a performance do desempenho de um modelo de controle de estoques, é essencial para qualquer organização estabelecer os indicadores necessários a serem monitorados. Lustosa *et al.* (2008) relatam que os indicadores mais utilizados na gestão de estoques são relacionados ao fluxo de materiais. Dentre estes, as principais medidas de desempenho são estoque médio, cobertura, giro e nível de serviço.

Estoque Médio

Este indicador mensura a quantidade média mantida em estoque ao longo de um determinado período. Ele é importante para se ter dimensão do nível de estoque de cada SKU,

porém possui limitações caso analisado individualmente por conta de não considerar os diferentes níveis de demanda que cada SKU possui.

Cobertura de Estoque

A cobertura de estoque indica quanto tempo em média o estoque dura. Ele pode ser calculado da seguinte forma:

$$\text{Cobertura de Estoque} = \frac{\text{Estoque médio do período}}{\text{Demanda média do período}} \quad (10)$$

Giro de Estoque

O giro de estoque representa o inverso da cobertura, ou seja, ele mede a rotatividade do fluxo dos estoques e pode ser calculado da seguinte maneira:

$$\text{Giro de Estoque} = \frac{\text{Demanda do período}}{\text{Estoque médio do período}} \quad (11)$$

Embora os indicadores apresentados até aqui sejam importantes, Lustosa et al. (2008) ainda afirmam que podem ser insuficientes. Avaliar o indicador da cobertura, por exemplo, não permite entender se esta é suficiente para atender a demanda por completo sem estocar em excesso. Desse modo, esta é a importância dos indicadores de nível de serviço, que podem ser apresentados de duas maneiras diferentes segundo Garcia *et al.* (2005):

Proporção de Ciclos de Reposição sem Faltas (CSL – Cycle Service Level)

Este indicador, também conhecido por P1, pode ser entendido como a probabilidade de não haver ruptura de estoque durante o ciclo de reposição, que pode ser apenas o *lead time* em caso de reposição contínua ou o *lead time* acrescido do período de revisão no caso de revisão periódica. Ele representa o percentual de ciclos de ressuprimento no qual não ocorreu nenhum momento de escassez do SKU.

Segundo Biazzi (2019), o valor de CSL desejado pode ser usado para determinar o coeficiente de segurança k utilizado nas definições de fórmulas para cálculo do estoque de

segurança. Assumindo que a demanda segue uma distribuição normal, o coeficiente k passa a ser denominando z , e essa relação pode ser definida do seguinte modo:

$$F(z) = CSL \quad (12)$$

Onde $F(z)$ representa a função de probabilidade acumulada da distribuição normal padrão, que pode ser calculada por meio da seguinte equação:

$$F(z) = \int_{-\infty}^z \frac{1}{\sqrt{2\pi}} * e^{\frac{-u^2}{2}} du \quad (13)$$

Disponibilidade (FR – Fill Rate)

Este indicador, também conhecido por P2, pode ser entendido como a proporção da demanda que é atendida sem faltas. Pode ser calculado como a razão da demanda efetivamente atendida sobre a demanda total. Assim como o CSL, Biazzi (2019) também afirma que é possível utilizar o FR para determinar o coeficiente de segurança k utilizado nas definições de fórmulas para cálculo do estoque de segurança. Assumindo que a demanda segue uma distribuição normal, o coeficiente k passa a ser denominando z , e essa relação pode ser definida de diferentes maneiras dependendo se o modelo de controle de estoque considera atraso no atendimento da demanda (equação 14) ou se considera perda de venda (equação 15).

$$I(z) = \frac{Q}{\sigma_L} * (1 - FR) \quad (14)$$

$$I(z) = \frac{Q}{\sigma_L} * \frac{(1-FR)}{FR} \quad (15)$$

Em caso de revisão periódica, bastaria utilizar σ_{T+L} ao invés de σ_L . O termo $I(z)$ representa a função da integral de perda da distribuição normal padrão, que pode ser calculada por meio da seguinte equação:

$$I(z) = \int_z^{\infty} (u - z) * \frac{1}{\sqrt{2\pi}} * e^{\frac{-u^2}{2}} du \quad (16)$$

Para se calcular z a partir de um dado $I(z)$, Silver *et al* (1998) propõe a seguinte fórmula:

$$Z = \frac{a_0 + a_1k + a_2k^2 + a_3k^3}{b_0 + b_1k + b_2k^2 + b_3k^3 + b_4k^4} \quad (17)$$

Onde:

$$k = \sqrt{\ln\left(\frac{25}{I(z)^2}\right)}$$

$$a_0 = -5,3925569$$

$$a_1 = 5,6211054$$

$$a_2 = -3,8836830$$

$$a_3 = 1,0897299$$

$$b_0 = 1$$

$$b_1 = -7,2496485 * 10^{-1}$$

$$b_2 = 5,07326622 * 10^{-1}$$

$$b_3 = 6,69136868 * 10^{-2}$$

$$b_4 = -3,29129114 * 10^{-3}$$

2.2 PREVISÃO DE DEMANDA

2.2.1 Contexto da Previsão de Demanda no Varejo

De acordo com Arunraj *et al* (2015), a previsão de demanda no varejo pode ser feita de maneira qualitativa, quantitativa ou uma combinação entre as duas. Os métodos qualitativos são baseados em avaliações subjetivas, que são aplicadas quando não há dados suficiente para se adotar um método quantitativo. Os métodos quantitativos podem ser classificados em

modelos de séries temporais, modelos causais e modelos híbridos. Os modelos de séries temporais baseiam-se apenas na série histórica de vendas enquanto os modelos causais se baseiam na relação de causa e efeito entre vendas e fatores que influenciam a demanda. Já os modelos híbridos são uma combinação tanto de modelos de séries temporais quanto modelos causais.

Ainda segundo Arunraj *et al* (2015), a variação na demanda pode ser categorizada em:

- **Flutuações de curto prazo:** Nesta categoria encaixam-se as variações geradas por ações promocionais e por conta de feriados e datas festivas como *Black Friday* e Natal, por exemplo.
- **Padrões sazonais de médio prazo:** Trata-se de padrões de demanda observados por um período maior do que simplesmente em datas pontuais (e.g. feriados). Aqui encaixam-se, por exemplo, itens que são impactados por uma determinada estação do ano, como verão ou inverno.
- **Tendências de longo prazo:** Geralmente refletem situações econômicas que impactam o mercado no qual o varejo está inserido. Por exemplo, em cenários de recessão econômica e alta taxa de desemprego, pode ser esperado uma queda na demanda principalmente se o público-alvo envolve a população de mais baixa renda.

Uma maneira alternativa de se categorizar as variações na demanda seria dividir entre fatores internos e externos à organização. Alguns exemplos de fatores internos são o preço de venda estabelecido, ações de marketing e rupturas de estoque, enquanto fatores externos podem ser variações de temperatura e feriados, por exemplo.

Essas variações na demanda tornam mais difícil a tarefa de gerar previsões de demanda precisas e consequentemente determinar qual a quantidade ideal de produto a ser comprada. Essa variação pode levar a dois tipos de erros: ruptura ou excesso de estoque. Excesso de estoque pode levar a maiores custos e dificuldades de armazenamento e necessidade de forçar ações promocionais levando a margens mais baixas, enquanto a falta de estoque leva a perda de vendas e possivelmente perda de confiança do cliente e deterioração da imagem no mercado. Desse modo, é importante considerar esses fatores tanto internos ou externos, de curto, médio ou longo prazo, para se obter uma melhor acurácia na previsão de demanda.

Outra dificuldade em lidar com previsões de demanda baseia-se na granularidade da previsão. Huang *et al* (2014) afirmam que fazer previsões no nível SKU é um problema completamente diferente do que fazer uma previsão de vendas geral da organização. Os

varejistas costumam se basear nas previsões de venda no nível SKU ou ainda no nível SKU-ponto de venda para tomar suas decisões de planejamento de estoques.

A dificuldade de tratar granularidades pequenas, seja na dimensão de produto, local ou tempo, é que os dados históricos contêm muito mais ruídos do que em níveis mais agregados e podem exibir padrões diferentes destes. Adotar uma granularidade mais fina em qualquer uma dessas três dimensões pode levar muitas vezes a uma série histórica de demanda intermitente. Kolassa (2016) aponta que as recentes tendências em volta de “*Big Data*” têm levado os varejistas a adotarem sistemas de banco de dados mais robustos capazes de armazenar e processar dados em granularidades menores, como SKU x Loja x Dia. Dekker *et al* (2004) ainda demonstram que fazer previsões utilizando a granularidade temporal diária pode ser mais vantajoso, dado que a agregação das previsões diárias tende a gerar resultados melhores do que as previsões utilizando uma granularidade já agregada.

Outro ponto relevante tratando-se de previsão de demanda em varejistas é o fato de que séries de vendas podem conter valores nulos. Assumindo que esses valores nulos não sejam por falhas de processo ou do sistema, eles podem indicar que de fato não teve demanda para o produto no período observado ou que não havia estoque para ser vendido. Quando se trata do segundo caso, é necessário fazer algum tipo de tratamento para que os resultados da previsão não sejam enviesados para valores mais baixos, denominado “*downward bias*” (Lokad, 2016).

Tabela 3 - Possíveis abordagens para lidar com *stockouts* em séries de vendas

AÇÃO	VANTAGENS	DESVANTAGENS
Exclusão	Série limpa; “demanda verdadeira”	Remove a possibilidade de enxergar eventos que levaram ao <i>stockout</i>
Inclusão	Se boa a estimativa, tem-se uma série limpa, contínua e pode-se usar muitos modelos	Dificuldade de fazer a estimativa requer muito conhecimento e histórico dos produtos, lojas etc.
Flagging (variável categórica)	Permite categorizar eventos de <i>stockout</i> para tratá-los diferentemente (ex: em regressão)	Não incorpora a magnitude do impacto do evento
Velocidade de vendas	Revela o comportamento do período com o estoque mais nivelado	Período de reabastecimento pode estar sofrendo efeitos de sazonalidade ou outros eventos.
Quantil (Ex: 75%)	Tratamento fácil, com segurança ao reduzir a probabilidade de perda de venda, baseia-se em histórico	Pode gerar um nível médio de demanda alto


Fonte: Adaptado de Alloy (2019) e Lokad (2016)

2.2.2 Métodos Univariados de Previsão de Demanda por Séries Temporais

Os métodos preditivos com base em séries temporais necessitam apenas dos valores da variável a ser prevista ao longo do tempo. Esses métodos são mais recomendados quando não há disponibilidade de dados complementares que ajudam a explicar o comportamento da demanda (Hyndman *et al*, 2018).

Uma série temporal é uma coleção de observações feitas sequencialmente ao longo do tempo, de modo que as observações vizinhas são dependentes e deseja-se analisar e modelar essa dependência (Ehlers, 2007). As séries temporais podem ser caracterizadas de acordo com alguns componentes: nível, tendência, ciclo, sazonalidade e um componente residual, ilustrados na Figura 10.

Figura 10 - Representação gráfica dos componentes de uma série temporal




Fonte: Elaboração própria

- **Nível:** É o patamar de valor médio que a série temporal assumiria caso não houvesse influência dos demais componentes (tendência, sazonalidade, ciclos ou incertezas).
- **Tendência:** É um padrão de crescimento ou decrescimento da série. Esse padrão pode se expressar de diversas maneiras, podendo ser linear ou exponencial por exemplo.

- **Ciclos:** São padrões mais longos de aumentos e quedas em torno da linha de tendência na série temporal que não ocorrem em intervalos de tempo regulares.
- **Sazonalidade:** É um padrão de variação da série temporal que ocorre em um intervalo regular de tempo. Quando a magnitude das flutuações sazonais varia dependendo do nível da série, a sazonalidade é dita multiplicativa. Caso contrário, ou seja, as flutuações são mais ou menos constantes independentemente do nível da série, ela pode ser classificada como aditiva. A Figura 11 ilustra essas classificações.
- **Resíduo:** Capta todos os efeitos que não foram incorporados pela série temporal através das componentes descritas anteriormente.

Além disso, uma outra maneira de caracterizar uma série temporal é de acordo com sua estacionariedade. Uma série é dita estacionária quando sua média, variância e autocorrelação são constantes ao longo do tempo. Em princípio, séries com tendência e sazonalidade não são estacionárias. Como diversas técnicas analíticas de séries temporais dependem da condição de estacionariedade da série para funcionarem, em geral séries não estacionárias acabam passando por um tipo de transformação para se tornarem estacionárias (Amaral, 2018).

Figura 11 - Comparação de série estacionária com série não estacionária



Fonte: Amaral (2018)

Além de métodos mais simplistas, como uma média ou média móvel, os métodos mais comumente empregados são o ARIMA e suavização exponencial, além de suas variações como SARIMA e Holt Winters (Loureiro, 2018). A seguir serão apresentados os principais métodos de previsão com base em séries temporais.

Média

A previsão é determinada a partir da média dos valores históricos disponíveis.

$$\hat{y}_{T+h} = \bar{y} = \frac{\sum_{i=1}^T y_i}{T} \quad (18)$$

Onde:

T: Período atual

h: Horizonte da previsão de demanda

y_i : Valor observado em um determinado período i

Naive

A previsão é determinada com base apenas na observação mais recente.

$$\hat{y}_{T+h} = y_T \quad (19)$$

Naive sazonal

Dado uma sazonalidade previamente determinada, determina-se a previsão com base na observação mais recente da posição correspondente do período dentro da sazonalidade. Por exemplo, se uma série possui sazonalidade semanal, a previsão para o próximo domingo será igual ao valor observado no último domingo.

$$\hat{y}_{T+h} = y_{T+h-m(k+1)} \quad (20)$$

Onde:

m: duração do período sazonal

k: é a parte inteira da divisão $(h-1)/m$

Média móvel

A média móvel é um método de previsão calculado a partir da média de um período fixo pré-determinado (n) das observações mais recentes.

$$\hat{y}_{T+h} = \frac{\sum_{i=T-n+1}^T y_i}{n} \quad (21)$$

Suavização exponencial

Enquanto a média móvel atribui o mesmo peso para todas as observações do período considerado, o método de suavização exponencial atribui pesos distintos que decrescem geometricamente, ou seja, dando mais valor para as observações mais recentes. O método de suavização exponencial adequado depende do tipo de tendência e sazonalidade que a série temporal apresenta, como indica a Tabela 3. O método NN refere-se à suavização exponencial simples, enquanto o método AA refere-se ao método de Holt-Winters aditivo.

Tabela 4 - Métodos de suavização exponencial

COMPONENTE DE TENDÊNCIA	COMPONENTE DE SAZONALIDADE		
	N (Nenhuma)	A (Aditiva)	M (Multiplicativa)
N (Nenhuma)	NN	NA	NM
A (Aditiva)	NA	AA	AM
Aditiva Amortecida	AaN	AaA	AaM
Multiplicativa	MN	MA	MM
Multiplicativa Amortecida	MaN	MaA	MaM

Fonte: Adaptado de Hyndman, 2011

Suavização exponencial simples

O método de suavização exponencial simples (SES) não assume nenhum componente de tendência nem de sazonalidade na série temporal. Desse modo, assume que a demanda oscila em torno de um valor base constante, que é corrigido a cada período com a incorporação de um novo dado na série histórica. A previsão pode ser calculada de acordo com a equação:

$$F_t = B_t = \alpha * D_t + (1 - \alpha) * B_{t-1} \quad (22)$$

Onde:

F_t : previsão para o período t

B_t : base para o período t

D_t : demanda do período t

α : constante de suavização entre 0 e 1

Suavização exponencial com tendência e sazonalidade (Holt-Winters)

Como mencionado anteriormente, este método incorpora tanto um componente de tendência quanto de sazonalidade. São inclusas uma variável que reflete o crescimento da demanda de um período para o outro sendo atualizada exponencialmente, assim como uma variável de sazonalidade calculada como a proporção entre a demanda média do período e o valor base. Os parâmetros e previsões são calculados de acordo com as seguintes fórmulas:

$$B_t = \alpha * \frac{D_t}{I_{t-L}} + (1 - \alpha) * (B_{t-1} + T_{t-1}) \quad (23)$$

$$T_t = \beta * (B_t - B_{t-1}) + (1 - \beta) * T_{t-1} \quad (24)$$

$$I_t = \gamma * \frac{D_t}{B_t} + (1 - \gamma) * I_{t-1} \quad (25)$$

$$F(t+k) = (B_t + kT_t) * I_{t-L+k}, \quad k = 1, 2, \dots \quad (26)$$

Onde:

D_t : demanda do período t

B_t : base para o período t

T_t : tendência no período t

I_t : índice de sazonalidade do do período t

α : constante de suavização para base (entre 0 e 1)

β : constante de suavização para tendência (entre 0 e 1)

γ : constante de suavização para sazonalidade (entre 0 e 1)

$F(t+k)$: previsão para um horizonte de k períodos a frente do instante t

L : extensão do ciclo sazonal

Processo autorregressivo integrado de média móvel (ARIMA)

Os modelos ARIMA (*AutoRegressive Integrated Moving Average*) buscam descrever as autocorrelações nos dados da série temporal. Estes modelos requerem séries estacionárias e não consideram um componente de sazonalidade. Amaral (2019) explica os componentes do ARIMA da seguinte maneira:


AR – *AutoRegressive*: avalia a autocorrelação entre os períodos da série e extrai essa influência.

I – *Integrated*: aplica uma diferenciação na série temporal para transformá-la em estacionária, se necessário. Normalmente, apenas uma ou duas diferenciações são necessárias para que a série se torne estacionária.

MA – *Moving Average*: avaliar os erros entre períodos e extrair a influência destes

Uma notação comum para os modelos ARIMA é descrevê-los como uma combinação de parâmetros (p,d,q), como indica a Figura 12.

Figura 12 - Componentes do modelo ARIMA



Fonte: Elaboração própria

A interpretação desses parâmetros pode ser feita da seguinte maneira:

$p = 1$: uma determinada observação pode ser explicada pela observação prévia e por um componente residual (erro).

$p = 2$: uma determinada observação pode ser explicada por duas observações prévias e por um componente residual.

$d = 0$: não é aplicada diferenciação.

$d = 1$: é aplicada diferenciação de primeira ordem.

$d = 2$: é aplicada diferenciação de segunda ordem.

q = 1: o erro de uma determinada observação pode ser explicada pelo erro da observação prévia.

q = 2: o erro de uma determinada observação pode ser explicada pelo erro de duas observações prévias.

Amaral (2018) indica que uma possível maneira de determinar os parâmetros seria por meio de:


p: análise do gráfico de PACF (*Partial AutoCorrelation Function*)

d: testes estatísticos para checar estacionariedade, como *Dickey-Fuller*, *KPSS* e *Philips-Perron*.

q: análise do gráfico de ACF (*AutoCorrelation Function*)

Um exemplo de interpretação do gráfico de PACF pode ser observado na Figura 13.

Figura 13 - Função de Autocorrelação Parcial (PACF)



Fonte: Suporte Minitab

No gráfico da Figura 13 nota-se a existência de uma correlação significativa no período (*lag*) 1 seguido por correlações que não são significativas. Este padrão indica um termo autorregressivo de ordem 1.

O modelo completo do ARIMA pode ser escrito da seguinte maneira:

$$\Delta^d Y_t = c + \sum_{i=1}^p \varphi_i * \Delta^d Y_{t-1} + \sum_{i=1}^q \theta_i * \varepsilon_{t-i} + \varepsilon_t \quad (27)$$

Onde:

Y_t : série temporal no instante t

Δ^d : diferenciação para torna a série estacionária

p : ordem da parte autorregressiva

d : ordem da diferenciação

q : ordem da parte da média móvel

ϕ : parâmetro estimador da parte autorregressiva

θ : parâmetro estimador da parte da média móvel

c : uma constante

ε : erro residual, também chamado de ruído branco (parcela não auto correlacionada da série)

Processo sazonal autorregressivo integrado de média móvel (SARIMA)

A diferença do SARIMA (*Seasonal AutoRegressive Integrated Moving Average*) para o ARIMA é que leva em consideração também a sazonalidade da série temporal. A notação utilizada passa de (p, d, q) para $(p, d, q) \times (P, D, Q)_s$ onde esta última parcela representa as ordens da parte autorregressiva, da diferenciação e da média móvel para o componente sazonal da série temporal.

O modelo completo do SARIMA pode ser escrito da seguinte maneira:

$$\nabla^D \Delta^d Y_t = c + \sum_{i=1}^p (\phi_i * \nabla^D \Delta^d Y_{t-i}) + \sum_{i=1}^q (\theta_i * \varepsilon_{t-i}) + \sum_{i=1}^P (\Phi_i * \nabla^D \Delta^d Y_{t-is}) + \sum_{i=1}^Q (\Theta_i * \varepsilon_{t-is}) + \varepsilon_t \quad (28)$$

Onde:

∇^D : diferenciação do componente sazonal

P : ordem da parte sazonal autorregressiva

D : ordem da diferenciação do componente sazonal

Q : ordem da parte sazonal da média móvel

Φ : parâmetro estimador da parte sazonal autorregressiva

Θ : parâmetro estimador da parte sazonal da média móvel

S: duração do ciclo sazonal

2.2.3 Métodos Causais de Previsão de Demanda

Ao invés de modelar uma série temporal utilizando apenas dados sobre a variável a ser prevista, Arunraj *et al* (2015) propõem a utilização do método SARIMAX para contornar a ausência da captura de efeitos de variáveis externas que possam influenciar na demanda. O universo de modelos causais vem sendo explorado cada vez mais principalmente com avanços de capacidade computacional e inteligência artificial. Loureiro *et al* (2018) propõem em seu estudo a comparação de seu modelo utilizando redes neurais (DNN – *Deep Neural Networks*), com outras técnicas comumente usadas nesse campo, como árvores de decisão, florestas aleatórias, SVR (*Support Vector Regression*) e redes neurais artificiais (ANN – *Artificial Neural Networks*).

Entretanto, James (2013) analisa que, à medida em que os modelos se tornam mais sofisticados e complexos, nem sempre eles são os preferíveis para serem adotados. Isso ocorre porque em muitos casos o objetivo com um modelo não é somente sua acurácia, mas também a sua interpretabilidade e capacidade de inferência de quais são as variáveis que mais impactam nos resultados e como se dá a influência destas.

A seguir são descritos brevemente alguns dos modelos causais mais comumente utilizados:

Método dos Mínimos Quadrados (MMQ)

O Método dos Mínimos Quadrados (MMQ), ou Mínimos Quadrados Ordinários (MQO) ou OLS (do inglês *Ordinary Least Squares*) modela o relacionamento entre uma variável dependente e um conjunto de variáveis independentes. De acordo com Pohlman & Leitner (2003), o valor da variável dependente é definido como uma combinação linear das variáveis independentes adicionada de um termo de erro (residual), como expresso na equação (29). Assume-se que os erros são normalmente distribuídos e com média igual a zero. Os estimadores dos coeficientes β_i são definidos de maneira a minimizar a soma dos quadrados dos resíduos da regressão.

$$Y_t = \beta_0 + \sum_{i=1}^k \beta_i * X_{i,t} + \varepsilon \quad (29)$$

Onde:

β_i : coeficiente da regressão da variável externa i

β_0 : constante da regressão das variáveis externas

k: total de variáveis independentes consideradas

$X_{i,t}$: valor observado da variável i no instante t

Y_t : valor observado da variável dependente no instante t


ε_t : termo do erro (resíduo) no instante t

Árvores de Decisão (*Decision trees*)

De acordo com Loureiro *et al* (2018), árvores de decisão são técnicas comumente utilizadas para construir modelos tanto de regressão quanto de classificação em uma estrutura em forma de árvore. No caso de previsão de demanda, estamos lidando com uma variável numérica, portanto nos importa apenas as árvores de decisão para regressão. A grande popularidade deste método é o seu fácil uso e interpretabilidade pelos usuários. Entretanto, a performance deste método não é considerada entre as melhores e normalmente é tratado como um método não robusto.

Este é um método recursivo que divide a amostra inicial em subamostras com base nos resultados observados nas variáveis preditoras e em suas interações. Desse modo, vão se formando grupos para o qual a variável a ser prevista apresenta um comportamento homogêneo dentro deles e heterogêneo fora dos mesmos. A Figura 14 ilustra a estrutura de uma árvore de decisão que parte do topo e gera subamostras até se chegar em valores de resposta R.

Figura 14 - Estrutura de uma árvore de decisão



Fonte: James (2013)

Floresta Aleatória (*Random Forest*)

Loureiro *et al* (2018) apresentam esta técnica como uma técnica derivada das árvores de decisão. Afirmam que este método foi desenvolvido para aumentar a acurácia das previsões em comparação com árvores de decisão, tendo em vista que esse último método apresenta alta sensibilidade às pequenas variações nos dados.

A técnica do Random Forest se baseia num conjunto de árvores de decisão seguida pelo cálculo do valor médio das previsões observadas no nó final de cada árvore. Essa característica evita a falta de robustez gerada por uma única árvore de decisão. Nessa abordagem, cada árvore é gerada usando uma subamostra de variáveis independentes escolhidas aleatoriamente.


2.2.4 Seleção de Variáveis em Modelos Causais de Previsão de Demanda

Quando variáveis externas são incorporadas em um modelo causal de previsão de demanda, uma questão a ser tratada é o problema de se considerar um número excessivo de variáveis explanatórias (Huang *et al* 2014). Modelos de séries temporais podem facilmente

sofrer do fenômeno de *overfitting*, isto é, o modelo se adapta muito bem aos dados com os quais está sendo treinado, porém não generaliza bem para novas observações.

Desse modo, é necessário adotar um mecanismo capaz de identificar, selecionar e refinar as variáveis explanatórias mais relevantes. Huang *et al* (2014) afirmam que o método mais popular é a seleção *stepwise*. Esse método inicia com um modelo de regressão “nulo” e vai adicionando variáveis explanatórias passo-a-passo. A cada passo, a variável fora do modelo com a contribuição mais significativa é considerada para ser adicionada, enquanto a variável já usada pelo modelo que contém a contribuição menos significativa é considerada para ser removida. As decisões de inclusão e exclusão de variáveis do modelo são tomadas com base em um valor de referência, como por exemplo 5% de significância.

Figura 15 - Fluxograma da seleção *stepwise*



Fonte: Research Gate, 2018. Disponível em: <https://www.researchgate.net/figure/The-Stepwise-Regression-Process_fig1_322098364>

Huang *et al* (2014) também afirmam que apesar de popular, o método de seleção *stepwise* recebe algumas críticas na literatura por muitas vezes reter variáveis irrelevantes e deixar de incluir variáveis relevantes. O método LASSO (*Least Absolute Shrinkage and Selection Operator*) é apresentado como uma alternativa mais robusta. Esse procedimento estima um modelo de regressão incluindo todas as potenciais variáveis explanatórias, mas com uma restrição para a soma dos valores absolutos de todos os coeficientes dos parâmetros. A equação a seguir demonstra essa enunciação.

$$Y = X\beta + u, \text{ sujeito a } \sum_{j=1}^N |\beta_j| = \eta, \quad \eta \leq \eta_0 \quad (30)$$

Onde:

Y: vetor com os valores padronizados da variável dependente

X: matriz com os valores padronizados das variáveis explanatórias

u: erro aleatório

β : vetor de coeficientes das variáveis explanatórias

N: número de coeficientes a serem determinados

η_0 : fator de encolhimento que equivale a soma de todos os coeficientes

Quando esta restrição for aplicada, alguns coeficientes tendem a zero e, consequentemente, suas respectivas variáveis explanatórias serão removidas do modelo de regressão. No processo de seleção, o fator de encolhimento é determinado de acordo com a métrica *Akaike Information Criterion* (AIC).

2.2.5 Métricas de Mensuração de Erros

Mensurar o desempenho dos modelos de previsão é essencial para conseguir calibrá-los adequadamente para aumentar sua acurácia, assim como podem ser utilizados na definição de estoques de segurança como discutido na seção sobre gestão de estoques. Entretanto, existem diversas maneiras apresentadas na literatura sobre como mensurar o erro, cada uma com suas vantagens e desvantagens. Algumas das métricas mais populares para mensuração de erros de previsão são:

Erro Médio (ME – Mean Error)

O erro médio é bastante utilizado para indicar se o modelo apresenta ou não um viés ou erro sistemático, dado que os desvios positivos se anulam com os desvios negativos.

$$ME = \frac{\sum_{t=1}^n (D_t - F_t)}{n} \quad (31)$$

Onde:

F_t : valor previsto no instante t

D_t : valor real no instante t

Erro Absoluto Médio (MAE – *Mean Absolute Error*)

Este método envolve o cálculo de desvios absolutos, evitando o cancelamento de desvios positivos com desvios negativos. De acordo com Huang *et al* (2014), o MAE é muito utilizado na prática, porém é criticado por ser dependente de escala. Supondo que um modelo tem uma boa performance para uma categoria de produtos com alto volume de vendas, mas uma performance ruim para outra categoria de menor volume de vendas, os resultados provenientes da categoria mais impactante irão dominar os resultados agregados e podem levar à falsa impressão de que o modelo performa bem de maneira universal entre todas as categorias de produtos.

$$MAE = \frac{\sum_{t=1}^n |D_t - F_t|}{n} \quad (32)$$

Erro Absoluto Escalado Médio (MASE – *Mean Absolute Scaled Error*)

O MASE pode ser considerado como uma média aritmética ponderada baseada nas variações dos dados de venda no horizonte de previsão. Ele basicamente compara o MAE da previsão de demanda com o MAE do método Naive de previsão, que é utilizado como *benchmark*. Desse modo valores de MASE abaixo de 1 indicam uma performance superior ao *benchmark*. Alternativamente, pode-se utilizar o Naive Sazonal como modelo *benchmark* também.

Este método possui boas propriedades como ser robusto a valores realizados iguais a zero e ser independente de escala.

$$MASE = \frac{MAE}{MAE_{Naive}} \quad (33)$$

Erro Percentual Absoluto Médio (MAPE – *Mean Absolute Percentage Error*)

O MAPE é a métrica mais utilizada na prática e tem como vantagem não ser dependente de escala, dado que calcula os erros de maneira percentual. Entretanto, o MAPE penaliza as previsões acima dos valores reais com um peso maior do que as previsões abaixo dos valores reais.

Além disso, o uso do cálculo percentual do erro pode ser facilmente distorcido quando os valores realizados e previstos são relativamente pequenos comparados com o erro de previsão, gerando nestes casos porcentagens de erro extremamente altas. Ainda mais, o MAPE não possui valor definido para quanto o valor realizado é nulo.

Essas características do MAPE o tornam pouco recomendável para mensurar erros de previsão de produtos de baixa demanda, onde o patamar de vendas é de uma magnitude similar ao patamar dos erros (Huang *et al*, 2014).

$$\text{MAPE} = \frac{\sum_{t=1}^n \left| \frac{D_t - F_t}{D_t} \right|}{n} \quad (34)$$

Erro Simétrico Percentual Absoluto Médio (sMAPE – *Symmetric Mean Absolute Percentage Error*)

Este método surge como uma alternativa ao MAPE para tentar contornar a desvantagem de se penalizar mais os erros acima dos valores reais do que os erros abaixo.

$$\text{sMAPE} = \frac{\sum_{t=1}^n \left| \frac{D_t - F_t}{(D_t + F_t)/2} \right|}{n} \quad (35)$$

Erro Quadrático Médio (MSE – *Mean Squared Error*)

No cálculo do MSE, cada desvio é elevado ao quadrado. Assim os desvios maiores acabam tendo peso maior, enquanto os desvios menores possuem menor peso, aumentando a sensibilidade a *outliers*. Este é um método dependente de escala e possui também como desvantagem a maior dificuldade de compreensão da magnitude do erro dado que são elevados ao quadrado.

$$MSE = \frac{\sum_{t=1}^n (D_t - F_t)^2}{n} \quad (36)$$

Raiz do Erro Médio Quadrático (RMSE – Root Mean Squared Error)


O RMSE trata-se apenas da raiz quadrada do MSE, de modo a tornar a métrica de mensuração de erros na mesma unidade de medida das séries de dados.

$$RMSE = \sqrt{MSE} \quad (37)$$

2.3 MAPEAMENTO DE PROCESSOS

Na seção 2.1 abordou-se o tema de controle de estoques com enfoque matemático, entretanto é importante salientar que controle de estoque também se trata de um processo. Uma das notações mais populares para o desenho de processos é a notação BPMN (*Business Process Model and Notation*). A notação BPMN é uma representação gráfica que modela as etapas dos processos de negócio de ponta a ponta. Ela permite aos colaboradores compreender mais facilmente seus procedimentos internos de maneira visual e padronizada.

Figura 16 – Elementos da notação BPMN no software Bizagi



Fonte: Longaray (2017)

O software *Bizagi* é muito utilizado para o desenho de processos na notação BPMN e conta com sete elementos principais que permitem representar os processos por meio de

fluxogramas: *Pool*, *Lane*, *Data Object*, Fluxo, Atividade, Evento e *Gateway*. A seguir é feita uma breve descrição de cada um desses elementos.

Pool e Lane

Os elementos *Pool* e *Lane*, respectivamente Piscina e Raia traduzidos para o português, são a base para a construção dos fluxogramas. A Piscina informa qual o processo que está sendo diagramado, enquanto as raias indicam os atores deste processo.

Figura 17 – Exemplo de utilização dos elementos *Pool* e *Lane*




Fonte: Longaray, 2017

Data Object e Fluxo

Artefatos são utilizados para agregar documentação visual ao diagrama, sendo que os objetos de dados (*Data Objects*) são os mais comumente utilizados. Os *Data Objects* representam os dados fluindo através dos processos de maneira a introduzi-los ou recebê-los em uma atividade. Já os fluxos representam a direção que as atividades seguem, desde o seu início até a sua conclusão.

Figura 18 - Exemplo de uso dos elementos Data Object e Fluxo




Fonte: Longaray, 2017

Atividade

Atividades simbolizam o trabalho que é executado em uma determinada etapa do processo. Ainda é possível resumir um conjunto de atividades em um elemento chamado “subprocesso”, de maneira a tornar a visualização mais compacta, sendo que o subprocesso é destrinchado numa Piscina diferente. Os subprocessos são representados pelo símbolo “+” na parte inferior do elemento.

Há também a possibilidade de classificar o tipo de atividade descrita. Os diferentes tipos de atividade podem ser observados na Figura 20 enquanto a Tabela 5 explica o significado de cada uma.

Figura 19 - Exemplo de utilização dos elementos Atividade e Subprocesso



Fonte: Longaray, 2017

Figura 20 - Diferentes tipos de atividade



Fonte: Longaray, 2017

Tabela 5 - Descrição dos tipos de atividades

TAREFAS	DESCRIÇÃO
Padrão	Não necessita especificação em maiores detalhes, pois sua compreensão é simples.
Envio	Utilizada quando há necessidade de trocas de mensagens com um participante externo para conclusão de determinada atividade.
Recebimento	É a contraparte da tarefa de envio, onde o participante externo recebe a mensagem enviada.
Usuário	Realizada por uma única pessoa com suporte computacional.
Serviço	Confere a um participante externo, normalmente via recurso tecnológico, informações para que a tarefa executada por ele seja concluída.
Manual	Atividade de esforço humano, sem a utilização de nenhum recurso computacional ou mecânico.
Script	Informa quando um código em um formato de script é utilizado na demonstração de <i>softwares</i> .
Regra de Negócio	Atende obrigatoriamente a regras estabelecidas pelo negócio para a conclusão de um processo.
<i>Loop</i>	Deve ser repetida inúmeras vezes até que o processo seja concluído, sempre informando sucesso ou fracasso a cada rodada.
Múltiplas Instâncias	Ocorre de forma similar ao <i>Loop</i> , mas utiliza <i>Data Objects</i> para sua conclusão.


Fonte: Longaray, 2017

Evento

Os eventos são representações gráficas que simbolizam um momento em que um processo se inicia ou finaliza, ou até mesmo representar um evento intermediário durante o processo. Um exemplo de uso de evento de início e término de processo pode ser visto na Figura 21.


Assim como as atividades, os eventos também podem receber diferentes classificações que podem ser vistas na Figura 22, enquanto a Tabela 6 explica o significado de cada uma.

Figura 21 - Exemplo de eventos de início e término de um processo



Fonte: Longaray, 2017

Figura 22 - Tipos de evento



Fonte: Longaray, 2017


Tabela 6 - Descrição dos tipos de evento

EVENTOS	DESCRIÇÃO
Mensagem	Informa quando uma atividade é iniciada através do recebimento de mensagens.
Tempo	Determina qual será o tempo limite para realização da atividade, pode ser mesclada com a Tarefa de <i>Loop</i> , para informar qual o prazo para reiniciar esta etapa do processo.
Cancelamento	Permite terminar um processo antes do fim previsto, devido a uma impossibilidade imediata de continuidade.
Condicional	Suspende uma tarefa temporariamente para atualização de alguma informação pendente.
Sinal	Reiniciado logo após a solução da pendência citada no evento condicional
Múltiplo	Origina o início de outras atividades concomitantes
Compensação	Permite acionar um segundo processo, substitutivo ao primeiro, que é cancelado devido à ocorrência de algum problema de continuidade, causado pelo solicitante.
Paralelo	Permite a execução de diversas atividades oriundas de finalização.
Escalação	Similar ao evento de compensação, ocorre, porém quando o problema de continuidade é causado pelo próprio organizador, que transfere a atividade para outro processo substituto.

Fonte: Longaray, 2017


Gateways

Os *gateways* são utilizados para controlar a interação das atividades no processo, mostrando a ramificação e a reunião do fluxo de tarefas. A Figura 23 demonstra a aplicação de um *gateway*, enquanto a Figura 24 e a Tabela 7 descrevem os diferentes tipos de *gateway*.

Figura 23 - Exemplo de aplicação de um *gateway*

Fonte: Longaray, 2017

Figura 24 - Tipos de Gateway



Fonte: Longaray, 2017

Tabela 7 - Descrição dos tipos de *gateway*

EVENTOS	DESCRIÇÃO
Padrão	Possibilita dois caminhos: avançar para a próxima atividade ou retornar a anterior.
Complexo	Iniciado somente quando uma série de parâmetros anteriores é atendida. Usado em casos que diversas variáveis são necessárias para autorizar um novo processo.
Baseado em Evento	Ocorre somente quando certa atividade é executada e que dará origem a mais de um processo, de acordo com a necessidade do solicitante.
Inclusivo	Permite a entrada de várias setas de fluxo: agrupa as atividades e permite a passagem delas para uma ou mais atividades sequenciais
Exclusivo	O fluxo segue por apenas um dos fluxos de saída. Pode ser utilizado para representar um desvio no fluxo.
Paralelo	O fluxo se divide em outros que ocorrem em paralelo.

Fonte: Adaptado de Longaray, 2017

2.4 SIMULAÇÃO

Uma maneira de testar alternativas de modelos de controle de estoques e avaliar seus indicadores antes de implementá-los é através de simulação. Rego & Mesquita (2015) realizaram um estudo sobre peças de reposição do setor automotivo no qual simularam 136 cenários para 10.032 SKUs usando dados de histórico de demanda de 6 anos e mensurando performance através dos custos totais e *Fill Rates* realizados. Santoro & Freire (2008) também apresentam um estudo de simulação para fazer uma análise comparativa do desempenho entre modelos de estoque reativos e ativos, quando submetidos a demandas com diferentes previsibilidades. O critério de avaliação utilizado também foi o custo.

De acordo com Banks *et al* (1998), simulação é a imitação da operação de um processo ou sistema real ao longo do tempo. Simulação envolve a geração de uma história artificial do sistema e a observação dessa história de modo a fazer inferências levando em conta as características da operação do sistema real sendo representado. Tanto sistemas reais quanto conceituais podem ser modelados e analisados por meio de simulação.

Banks *et al* (1998) lista vantagens e desvantagens a respeito do uso de simulação. Algumas delas são descritas a seguir na Tabela 8.


Tabela 8 - Vantagens e desvantagens do uso de simulação

VANTAGENS	DESVANTAGENS
Permite testar uma mudança proposta em algum processo sem comprometer recursos para sua aquisição/implantação	Os resultados da simulação podem ser difíceis de serem interpretados, como por exemplo determinar se uma observação é fruto das interações do sistema ou simplesmente da aleatoriedade dos <i>inputs</i>
Uma vez desenvolvido um modelo, é possível explorar a mudança de vários parâmetros, procedimentos, métodos e políticas sem o custo e a disrupção de se experimentar no sistema real	A modelagem de um projeto de simulação e suas respectivas análises podem demandar muito tempo e recursos. Economizar demais no uso de recursos podem levar a um modelo de simulação que não é suficiente para atender o objetivo do projeto
Permite melhor entendimento sobre as interações entre variáveis que compõem um sistema complexo e quais os impactos que elas geram na performance dele	O uso da simulação pode não ser a escolha mais adequada, principalmente em casos em que uma solução analítica é possível

Fonte: Adaptado de Banks *et al* (1998)

A Figura 25 ilustra a metodologia sugerida por Banks *et al* (1998) para projetos de simulação.

Figura 25 - Etapas de um projeto de simulação



Fonte: Banks et al, 1998

3 METODOLOGIA

A metodologia empregada neste estudo tem basicamente duas etapas: análise dos atuais processos da empresa e em seguida a proposição de novos modelos avaliados e comparados por meio de simulação. A seguir cada uma dessas etapas é descrita com mais detalhes.

3.1 REVISÃO DOS PROCESSOS DA EMPRESA

O objetivo do trabalho é propor melhorias para o processo de controle dos estoques da Empresa. Para isso, o processo e os modelos de controle de estoques e de previsão de demanda atualmente utilizados devem ser primeiro revisados. A revisão dos atuais processos será iniciada por um mapeamento dos mesmos, utilizando a metodologia BPMN (*Business Process Modeling Notation*) por meio do software *Bizagi*.

Espera-se que com o mapeamento dos processos, fique mais fácil de compreender quais são as oportunidades de melhoria no controle de estoques, assim como quais restrições o ambiente impõe a proposição de novas metodologias.

3.2 PROJETO DE SIMULAÇÃO

Após a revisão dos atuais processos, este estudo irá avaliar, por meio de simulações, os atuais modelos de previsão de demanda e controle de estoques e propor melhorias com base na comparação do desempenho de outros modelos simulados. Uma premissa do estudo é que os modelos propostos sejam de revisão periódica, adequado para gerenciar múltiplos itens de um mesmo fornecedor e se adequar a facilitação da rotina da área de suprimentos.

A metodologia utilizada para o desenvolvimento e análise dos modelos será similar à proposta por Banks et al. (1998). A seguir, descreve-se os passos do método.

Formulação do problema e definição dos objetivos e plano do projeto

Estas questões já foram apresentadas no capítulo 1. Em resumo, o problema consiste nas ineficiências do controle de estoques tanto do centro de distribuição quanto das lojas e que

serão aprofundados no diagnóstico a ser feito pela revisão dos atuais processos. Já o objetivo da simulação é responder qual dos novos modelos de previsão de demanda e controle de estoques avaliados obtêm a melhor performance acerca dos indicadores a serem estabelecidos a partir da revisão dos atuais processos, além de comparar a diferença de desempenho com o modelo atualmente empregado na Empresa.

Modelo Conceitual

Nesta etapa é onde o sistema real é investigado e abstraído para um modelo conceitual, uma série de relações lógicas e matemáticas acerca dos componentes e da estrutura do processo de revisão periódica dos estoques de múltiplos itens, incluindo previsões de demanda. Além disso, também são feitas as modelagens conceituais dos diferentes modelos de controle de estoques a serem testados.

Coleta de dados

Para avaliar os modelos por simulação, serão necessários dados de: vendas, custos, *lead times*, variáveis que podem impactar na demanda (ex: histórico de preços, *histórico de stockouts*), entre outros.

Após a coleta dos dados realizada durante o serviço de consultoria promovido durante meu período de estágio, os mesmos devem ser analisados para verificar a necessidade de executar algum tipo de tratamento para poder utilizá-los. Além disso, a partir dos dados é possível criar critérios de delimitação do escopo do estudo, de modo a determinar para quais produtos, quais lojas, quais CDs e em qual período os dados serão considerados.

Tradução do modelo, verificação e validação

A implementação do modelo computacional será feita em duas linguagens: VBA (*Visual Basic for Applications*) e *Python*. A escolha do VBA deve-se à interface com o *Excel* estes são utilizados para programar as simulações dos modelos de controle de estoques. A escolha do *Python* deve-se ao acesso às bibliotecas que permitem desenvolver com maior facilidade os algoritmos de previsão de demanda utilizados nos modelos de simulação.

Junto da implementação do modelo computacional, é necessário realizar verificações para ver se ele está desempenhando adequadamente. Essa verificação será feita de maneira contínua ao invés de esperar programar todo o modelo. Desse modo, é possível começar com um modelo menos complexo e ir verificando a cada novo recurso adicionado que aumenta a sua complexidade.

Já a validação corresponde em determinar se o modelo conceitual é uma representação precisa do sistema real que está sendo espelhado. No caso deste projeto, isso será feito comparando os resultados reais validados junto a Empresa com o modelo base, ou seja, aquele que replica os modelos atuais empregados.

Desenho experimental, produção de réplicas e análises

O desenho experimental consiste em determinar os cenários que serão simulados, incluindo o número de réplicas, assim como os parâmetros de inicialização do modelo. No contexto deste estudo, as réplicas podem ser necessárias, por exemplo, para conseguir avaliar cenários em que os valores de *lead time* são gerados aleatoriamente de acordo com alguma distribuição de probabilidades teórica.

Após rodar as réplicas do experimento delineado, seus resultados são utilizados nas análises de acordo com os indicadores de desempenho para o cenário sendo simulado. Baseado nessas análises, determina-se se é necessário rodar mais réplicas desse experimento ou se há cenários adicionais que precisam ser simulados.

Documentação, relatório e implementação

O resultado de todas as análises deve ser reportado de maneira clara e concisa. Isso permitirá ao cliente rever as formulações, as alternativas que foram consideradas, os indicadores utilizados na comparação das alternativas, os resultados dos experimentos e as recomendações. Toda essa etapa de documentação estará representada nos capítulos deste trabalho assim como nos anexos e apêndices. Desse modo, as recomendações e conclusões aqui desenvolvidas serão apresentadas para a Empresa e ela optará pela implementação ou não.

4 DESENVOLVIMENTO

Neste capítulo, serão revisados os dois principais processos relacionados ao escopo do trabalho discutido no capítulo 1. Trata-se do processo de compra de mercadorias e do processo de abastecimento das lojas, incluindo suas metodologias de cálculo e indicadores. Após a revisão dos processos, é elaborado um diagnóstico dos principais problemas apresentados.

Em seguida, são desenvolvidos modelos para simular o controle de estoques tanto do centro de distribuição quanto das lojas. São coletados os dados e feitos os respectivos tratamentos e delimitação do escopo. O método atual utilizado pela Empresa é abstraído para um cenário de simulação e este é comparado com outros cenários em que se variam os modelos de previsão de demanda e/ou os métodos de cálculo da necessidade de compra. Por fim, são descritos e analisados os principais resultados dos experimentos executados.

4.1 REVISÃO DOS PROCESSOS DA EMPRESA

4.1.1 Revisão do processo de compras

O processo de compras foi mapeado e está disponível no Apêndice – A. Neste mapeamento, algumas atividades foram condensadas em subprocessos para criar um fluxograma mais enxuto. Um destes subprocessos, entretanto, merece atenção: o processamento dos cálculos que geram as recomendações automatizadas de compras para cada SKU, que posteriormente serão analisadas pelos analistas da equipe de compras e validadas pela gestora da equipe, como aponta o fluxograma.

Para melhor entendimento do racional de cálculo, este será descrito em texto. Os dados utilizados no cálculo da necessidade de compras para um determinado SKU estão descritos abaixo. Destaca-se que a compra é calculada para o CD de Manaus, que é o CD responsável por atender as vendas do ecommerce, além de abastecer as lojas e outros CDs de pequeno porte.

E_{CD} : unidades do SKU atualmente disponíveis no CD principal (Manaus)

e_k : unidades do SKU atualmente disponíveis na loja k ou CD secundário k

T_{CD} : unidades do SKU atualmente em trânsito para o CD principal (Manaus), ou seja, as quantidades pendentes de pedidos feitos no passado a serem entregues pelos fornecedores

Vm_M : quantidade média mensal de unidades do SKU vendidas nos últimos 5 meses, excluindo os meses de maior e menor volume de vendas. Caso o histórico seja menor que 5 meses, considera-se todo o período.

C_{ABC} : classificação do SKU de acordo com a curva ABC

L_M : valor do mínimo múltiplo de compra, ou seja, valor em unidades do qual só se pode fazer pedidos de compra em unidades que sejam múltiplas do mesmo

Com esses dados de entrada, são calculadas algumas métricas intermediárias:

$$\text{Venda média diária (un)} = Vm_D = \frac{Vm_M}{30} \quad (38)$$

$$\text{Cobertura lojas (dias)} = C_L = \frac{\sum_{k=1}^n e_k}{V_D}, \text{ sendo } n \text{ o nº de lojas + CDs secundários} \quad (39)$$

$$\text{Cobertura alvo no CD principal (dias)} = C_{CD} = \begin{cases} 70, & C_{ABC} = A \\ 65, & C_{ABC} = B \\ 55, & C_{ABC} = C \end{cases} \quad (40)$$

$$\text{Cobertura máxima agregada das lojas (dias)} = C_{Max,L} = 45 \quad (41)$$

$$\text{Cobertura excedente lojas (dias)} = C_{Ex} = \begin{cases} 0 & , C_L < C_{MAX,L} \\ C_L - C_{MAX,L} & , C_L \geq C_{MAX,L} \end{cases} \quad (42)$$

$$\text{Estoque excedente lojas (un)} = E_{Ex} = C_{Ex} * V_D \quad (43)$$

$$\text{Estoque alvo (un)} = E_{Alvo} = C_{CD} * Vm_D \quad (44)$$

Por fim, calcula-se a quantidade de pedido necessária para o SKU:

$$\text{Necessidade CD principal (un)} = N_{CD} = E_{Alvo} - (E_{CD} + T_{CD} + E_{Ex}) \quad (45)$$

$$\text{Pedido de compra para CD principal (un)} = Q_{CD} = \begin{cases} 0 & , N_{CD} \leq 0 \\ L_M \left\lceil \frac{N_{CD}}{L_M} \right\rceil & , N_{CD} > 0 \end{cases} \quad (46)$$

Analisando o fluxograma de processos e o procedimento de cálculo, elaborou-se uma tabela com os principais problemas percebidos no processo atual.

Tabela 9 - Diagnóstico dos principais problemas processo atual de compras

NOME DO PROBLEMA	DESCRIÇÃO DO PROBLEMA	DESCRIÇÃO DAS CAUSAS	POSSÍVEIS AÇÕES
Calibração de parâmetros	SKUs de fornecedores com prazo de entrega abaixo da cobertura alvo calculada para o CD podem ficar com excesso de estoque, enquanto SKUs de fornecedores com prazo de entrega acima disso fiquem em ruptura de estoque.	Utilizam na prática as ideias de um modelo de controle de estoques com revisão periódica, porém não utilizam os parâmetros adequados. No racional de cálculo de pedido, o horizonte de tempo para o qual se calcula a necessidade de estoque de um SKU é determinado arbitrariamente de acordo com a curva ABC, sem levar em consideração dados como Lead Time do fornecedor e Período de Revisão.	Mudar a lógica do horizonte de tempo considerado para calcular o pedido de compra (passar a utilizar Lead Time e Período de Revisão).
Erros de previsão	Método de previsão suscetível a grandes erros de acurácia. Consequentemente, podendo levar mais frequentemente a casos de ruptura ou excesso de estoque.	O algoritmo adaptado de média móvel que é utilizado hoje trata-se de um método de previsão em teoria simples e que provavelmente não estaria entre os algoritmos de melhor performance, mesmo com a tentativa de se corrigir desvios gerados por eventos sazonais (comuns e constantes no setor do varejo), ao remover os meses de pico e vale dos últimos 5 meses.	Utilizar um método de previsão de demanda mais preciso.
Previsão quando há ruptura	Subestimar a previsão de vendas de SKUs que sofreram com rupturas de estoque no histórico, podendo levar a mais problemas de ruptura de estoque no futuro.	Não tratar as rupturas de estoque na série histórica de vendas. Ao utilizar a série de vendas original, sem nenhum tratamento, é provável que SKUs que tiveram problema de abastecimento nos últimos meses passem a ser comprados em volumes menores no futuro, dado que a média de vendas foi afetada pela sua disponibilidade.	Utilizar algum método de tratamento de rupturas de estoque na série histórica de vendas
Previsão quando há promoção	Ausência de método analítico para auxiliar na tomada de decisão de compra em caso de promoção de venda.	No varejo, um setor tão competitivo, é normal muitas vezes o consumidor ter o preço como um dos fatores prioritários para decisão de compra. Períodos de promoção, onde o aumento das vendas ocorreu por conta de uma baixa de preços, não seria distinguido dentro de uma previsão por média móvel por	Utilizar algum método de previsão de demanda que leve em consideração o preço praticado.

		exemplo, levando a uma provável incorreta previsão de alta nas vendas quando os preços se normalizam. Hoje, as informações de promoções informadas pelo time de Marketing servem mais para a equipe de compras ter a intuição simples de “comprar mais” destes produtos, a não ser que o motivo da promoção seja justamente para desovar estoque.	
Muito trabalho manual	Muitos recursos são desperdiçados pela alta necessidade de intervenção nas recomendações de compra.	Por conta de todos os problemas descritos anteriormente, em muitas ocasiões as recomendações de compra geradas pelo método atual têm de passar por um alto nível de intervenção com base no julgamento da equipe de compras, inclusive da gestora. Além de correr um risco maior por conta da exposição de tomar maioria das decisões de compra baseada no julgamento de uma pessoa, essa situação retira tempo relevante da equipe que poderia focar em outras atividades também importantes de suas rotinas, ou até mesmo possibilitar uma redução da equipe, alocando os membros em outras áreas/setores.	Utilizar algum método de previsão com maior acurácia, incluindo em período sazonais, de maneira a transmitir mais confiança para a equipe acatar a recomendação gerada sem necessidade de grandes intervenções manuais.
Decisões <i>ad hoc</i> na revisão de pedidos de compra	As recomendações de compra pouco embasadas não dão respaldo suficiente em algumas situações em que seria oportuno solicitar verba adicional que ultrapasse o limite do orçamento	Como as decisões de compra muitas vezes acabam não sendo tão bem fundamentadas por meio de dados, se torna difícil justificar a necessidade de um orçamento maior de compra de um produto que possa realmente ter um alto potencial de vendas	Utilizar algum método de previsão com maior acurácia, incluindo em período sazonais, de maneira a transmitir mais confiança para a equipe acatar a recomendação gerada.

Fonte: Elaborado pelo autor

4.1.2 Revisão do processo de abastecimento das lojas

O processo de abastecimento das lojas, também denominado de distribuição, foi mapeado e está disponível no Apêndice – B. Neste mapeamento, optou-se por não entrar em detalhes nas micro atividades de separação e transporte de mercadorias dado que o foco deste trabalho não se trata de análises de layout e arranjo físico do CD nem sobre a seleção de modais e otimização da malha logística.

O modelo de reabastecimento das lojas pode ser interpretado como um modelo de reposição periódica, no qual o período $T = 1$ dia (com exceção do sábado onde $T = 2$, tendo em vista que os CDs não realizam separações de Domingo), além de contar com um ponto de ressuprimento s e um estoque máximo S . Estes parâmetros (s, S) são informados numa tabela grade de referência armazenada no sistema SAP da Empresa e atualizados pela equipe de gestão do processo de distribuição mediante solicitações de lojistas ou de análises internas da própria equipe.

A Tabela 10, elaborada a partir de discussões com a equipe de gestão do processo de distribuição, apresenta o diagnóstico dos principais problemas percebidos no atual processo.

Tabela 10 - Diagnóstico dos principais problemas do processo atual de distribuição

NOME DO PROBLEMA	DESCRIÇÃO DO PROBLEMA	DESCRIÇÃO DAS CAUSAS	POSSÍVEIS AÇÕES
Calibração reativa de parâmetros	A falta de calibração adequada acaba levando a falta de estoques nas lojas de alguns produtos e o excesso de estoque de outros.	Os parâmetros de estoque máximo e ponto de ressuprimento são definidos principalmente de acordo com reclamações feitas pelos lojistas ou pela equipe comercial acerca de faltas de estoque ou excesso, implicando em dificuldades de armazenamento na loja. Desse modo, a equipe não tem um embasamento para se antecipar a possíveis problemas e nem de otimizar de maneira proativa os parâmetros, sem depender de alguma reclamação.	Uma possível ação seria realizar previsões de demanda na granularidade SKU-Loja e mudar o método de controle de estoque das lojas para considerar a previsão o estoque alvo daquele SKU para aquela loja. Alternativamente, poderia manter-se o método atual, porém testando outros parâmetros por meio de simulação de maneira a achar (s, S) mais adequados.

Abastecimento das lojas filiais	As lojas fora do Amazonas têm mais dificuldade de manter-se um bom nível de abastecimento. Historicamente, sempre apresentaram índices maiores de ruptura de estoque.	A equipe não leva em consideração os valores de Lead Time da distribuição na hora de definir os parâmetros, se baseia apenas no histórico de vendas e a capacidade de armazenamento da loja. Desse modo, historicamente as lojas filiais sempre apresentaram índices muito maiores de ruptura de estoque.	Mudar o método de controle de estoque que utilize previsão de demanda no nível SKU-Loja considerando o período do Lead Time + Período de Revisão. Alternativamente, pode-se manter o método atual, porém buscando obter melhores parâmetros por meio de simulação incluindo os parâmetros de Lead Time na mesma.
Falta de tempo para análises	Equipe não tem tempo para fazer análises de maneira proativa para calibrar os parâmetros de abastecimento das lojas.	O processo atual de abastecimento exige uma equipe que passa diariamente ajustando os parâmetros. Esses parâmetros são fixados em unidades de estoque do SKU, de modo que em datas com alta sazonalidade, como Black Friday e Natal por exemplo, é necessário ficar alterando constantemente os parâmetros para abastecer as lojas em maior quantidade nesses períodos.	As soluções propostas para os problemas tratados anteriormente também ajudariam a minimizar os efeitos deste problema.

Fonte: Elaborado pelo autor

4.1.3 Revisão dos indicadores utilizados para avaliação do estoque

De todos os indicadores citados no tópico 2.1.3 a respeito de indicadores de desempenho na gestão de estoques, a Empresa utiliza todos com exceção do *Cycle Service Level* (CSL). Ela corrobora com a afirmação de Lewis (1997) de que o CSL acaba sendo preterido

pelo *fill rate* (FR) muitas vezes pelo motivo de não ser uma métrica muito relevante do ponto de vista do consumidor.

Tratando-se do cálculo do FR, a Empresa simplifica o cálculo de maneira a considerar o indicador como a porcentagem dos dias em que havia estoque do determinado SKU. Medir a porcentagem de *stockout* (dias com estoque zerado) desobriga estimar quanto efetivamente faltou, que dependeria da estimativa da demanda para aquele dia. Além disso, em dias de *stockout* de um SKU, a demanda seria considerada perdida, algo comum no Varejo como discutido no capítulo de revisão de literatura, ao contrário de outras indústrias que muitas vezes conseguem atender os pedidos com atraso.

Entretanto, do ponto de vista gerencial, é muito comum analisar indicadores de maneira agregada ao invés de analisar somente cada SKU individualmente, de modo a se ter uma visão macro da situação. Deste modo, para os indicadores de estoque médio, giro e cobertura, calculam-se os estoques e a demanda em valores monetários, sendo assim possível agregar diferentes SKUs. Já para se analisar o FR de maneira agregada, é possível fazer a média ponderada do FR de cada SKU em cada Loja/CD pela venda média diária (em valores monetários) calculada com base somente nos dias sem *stockout*.

O FR também possui valores mínimos como alvo de acordo com a posição que o SKU se situa na curva ABC. Para produtos curva A, espera-se um FR acima de 85%; acima de 80% para produtos curva B e acima de 70% para produtos curva C. Em resumo, o objetivo da Empresa é manter um FR acima do mínimo esperado com o menor nível de estoque possível.

4.2 MODELAGEM E SIMULAÇÃO

Conforme descrito na seção de metodologia, nesta etapa é onde o sistema real e posteriormente os modelos alternativos a serem testados são abstraídos para uma série de relações lógicas e matemáticas acerca dos componentes e da estrutura do sistema.

4.2.1 Modelos de controle de estoques

Além do modelo do cenário base, elaborou-se outros 4 modelos alternativos, nomeados em ordem alfabética de A até D.

Modelo base de controle de estoques

O modelo base foi apresentado durante a seção de revisão de processos. Sua simulação foi desenvolvida considerando de maneira integrada as operações do CD e das lojas. Isto é, as necessidades de reposição de estoque das lojas serão atendidas apenas caso o CD tenha disponibilidade para isso no momento da revisão do estoque.

Além disso, como na prática o processo de separação da mercadoria no CD para abastecimento das lojas ocorre de madrugada, a prioridade do estoque do CD em um determinado dia de simulação é atender as vendas cujo estoque é despachado do mesmo. Com o estoque restante, é executada a distribuição para atender as necessidades das lojas. Caso o estoque disponível no CD não seja suficiente para atender as necessidades de todas as lojas, a priorização das lojas que serão atendidas ocorre de acordo com o código do SAP de cadastro da loja, de maneira a atendê-las em ordem crescente.

Quanto aos prazos de entrega, optou-se por considerar o *lead time* praticado pelos fornecedores como probabilístico, tendo em visto que na prática eles dificilmente seguem um valor fixo. Para isso, assumiu-se que eles seguem uma distribuição normal. Pelo fato de a cada pedido feito o *lead time* gerado ser aleatório, foi necessário adotar uma regra para evitar cruzamento de pedidos. Isto significa que um pedido feito num instante B não pode chegar no CD antes do pedido feito anteriormente no instante A.

Já quanto ao *lead time* de distribuição do CD para as lojas, este foi considerado constante tendo em visto que a Empresa tem amplo controle sobre este processo e consegue administrá-lo a ponto de torná-lo praticamente constante. Ainda mais, considera-se o Domingo como dia de folga dos trabalhadores no CD, ou seja, não é possível atender as necessidades de abastecimento das lojas nesse dia da semana.

As relações matemáticas que compõem a formulação do modelo de simulação do abastecimento de um SKU estão descritas a seguir:

$$\text{Dia da simulação: } d, d \in \mathbb{N}^* \quad (47)$$

$$\text{Dia de operação do CD: } w = \begin{cases} 1, & \text{data} \neq \text{Domingo} \\ 0, & \text{data} = \text{Domingo} \end{cases} \quad (48)$$

$$\text{Período de revisão do estoque do SKU no CD: } T \quad (49)$$

$$\text{Demanda do SKU na loja } k \text{ no dia } d: D_{k,d} \quad (50)$$

Demanda (Vendas) do SKU no CD no dia d: $D_{CD,d}$ (51)

Demanda (Distribuição) do SKU no CD no dia d: $Dist_{CD,d} = \sum_{k=1}^k N_{k,d}$ (52)

Previsão de demanda total feita no dia d para os k dias seguintes: $F_{d,k}$ (53)

Ponto de ressuprimento do SKU na loja k no dia d: $s_{k,d}$ (54)

Estoque máximo do SKU na loja k no dia d: $S_{k,d}$ (55)

Lead Time de distribuição do CD para loja k: LT_k (56)

Lead Time de entrega do fornecedor para o CD no dia d: $LT_{CD,d} =$

$$\begin{cases} 0 & , Q_{CD,d} = 0 \\ X \sim N(\mu, \sigma) & , Q_{CD,d} > 0 \end{cases}$$
 (57)

Lead Time no dia d do pedido em trânsito mais antigo feito para o CD: $LTent_{CD,d}$ (58)

Estoque disponível do SKU na loja k no início do dia d: $e_{k,d,inicio} = \begin{cases} S_{k,d} & , d = 1 \\ e_{k,d-1,fim} & , d > 1 \end{cases}$ (59)

Estoque disponível do SKU no CD no início do dia d: $E_{CD,d,inicio} =$

$$\begin{cases} \sum_{d=1}^{C_{CD}} D_{CD,d} + Dist_{CD,d} & , d = 1 \\ E_{CD,d-1,fim} & , d > 1 \end{cases}$$
 (60)

Estoque em trânsito do SKU para loja k no início do dia d: $t_{k,d,inicio} =$

$$\begin{cases} 0 & , d = 1 \\ t_{k,d-1,fim} & , d > 1 \end{cases}$$
 (61)

Estoque em trânsito do SKU para CD no início do dia d: $T_{CD,d,inicio} =$

$$\begin{cases} 0 & , d = 1 \\ T_{CD,d-1,fim} & , d > 1 \end{cases}$$
 (62)

Pedido do SKU feito para o CD no dia d: $Q_{CD,d} = \begin{cases} 0 & , d/T \notin \mathbb{N} \\ \text{equação (46)} & , d/T \in \mathbb{N} \end{cases}$ (63)

Entrada do SKU no CD no dia d: $Ent_{CD,d} = Q_{CD,d-LTent_{CD,d}}$ (64)

Necessidade do SKU na loja k no dia d: $N_{k,d} =$

$$\begin{cases} 0 & , e_{k,d,inicio} + t_{k,d,inicio} > S_{k,d} \\ S_{k,d} - e_{k,d,inicio} + t_{k,d,inicio} & , e_{k,d,inicio} + t_{k,d,inicio} \leq S_{k,d} \end{cases}$$
 (65)

Estoque do SKU disponível no CD para distribuição no dia d: $ED_d = E_{CD,d,inicio} + Ent_{CD,d} - V_{CD,d}$ (66)

Estoque do SKU disponível no CD para distribuição para a loja k no dia d: $ED_{k,d} =$

$$\begin{cases} N_{k,d} & , ED_d - \sum_{j=1}^k N_{j,d} > 0 \\ ED_d - \sum_{j=1}^{k-1} N_{j,d} & , ED_d - \sum_{j=1}^{k-1} N_{j,d} < N_{k,d} \\ 0 & , ED_d - \sum_{j=1}^{k-1} N_{j,d} \leq 0 \end{cases}$$
 (67)

$$\text{Pedido do SKU feito para a loja } k \text{ no dia } d: Q_{k,d} = \begin{cases} N_{k,d} * w, & N_{k,d} < ED_{k,d} \\ ED_{k,d}, & N_{k,d} \geq ED_{k,d} \end{cases} \quad (68)$$

$$\text{Entrada do SKU na loja } k \text{ no dia } d: Ent_{k,d} = Q_{k,d-LT_k} \quad (69)$$

$$\begin{aligned} \text{Vendas do SKU na loja } k \text{ no dia } d: V_{k,d} = \\ \begin{cases} e_{k,d,inicio} + Ent_{k,d}, & e_{k,d,inicio} + Ent_{k,d} < D_{k,d} \\ D_{k,d}, & e_{k,d,inicio} + Ent_{k,d} \geq D_{k,d} \end{cases} \end{aligned} \quad (70)$$

$$\begin{aligned} \text{Vendas do SKU no CD no dia } d: V_{CD,d} = \\ \begin{cases} E_{CD,d,inicio} + Ent_{CD,d}, & E_{CD,d,inicio} + Ent_{CD,d} < D_{CD,d} \\ D_{CD,d}, & E_{CD,d,inicio} + Ent_{CD,d} \geq D_{CD,d} \end{cases} \end{aligned} \quad (71)$$

$$\begin{aligned} \text{Estoque disponível do SKU na loja } k \text{ no fim do dia } d: e_{k,d,fim} = e_{k,d,inicio} + Ent_{k,d} - \\ V_{k,d} \end{aligned} \quad (72)$$

$$\begin{aligned} \text{Estoque disponível do SKU no CD no fim do dia } d: E_{CD,d,fim} = E_{CD,d,inicio} + Ent_{CD,d} - \\ V_{CD,d} - \sum_{k=1}^K Q_{k,d} \end{aligned} \quad (73)$$

$$\begin{aligned} \text{Estoque em trânsito do SKU na loja } k \text{ no fim do dia } d: t_{k,d,fim} = t_{k,d,inicio} - Ent_{k,d} + \\ Q_{k,d} \end{aligned} \quad (74)$$

$$\begin{aligned} \text{Estoque em trânsito do SKU para o CD no fim do dia } d: T_{CD,d,fim} = T_{CD,d,inicio} - \\ Ent_{CD,d} + Q_{CD,d} \end{aligned} \quad (75)$$

Para validação do cenário base, comparou-se o indicador de estoque médio total (CD + lojas) resultante da simulação com o estoque médio real do período. Entretanto, na prática, trata-se de uma validação com muitas complicações, tendo em vista que como descrito na seção de revisão dos processos, existem muitas intervenções manuais nos processos de compras que impedem que o modelo siga o cenário real fielmente. Além disso, os *lead times* sofrem com variações seja por indisponibilidade do fornecedor no momento do pedido ou por problemas logísticos durante a pandemia, por exemplo, tornando muito complexo traduzir essas informações de maneira certa no modelo de simulação.

De modo a tentar contornar este problema na validação, coletou-se com a Empresa uma lista de 20 SKUs que se julgou serem pouco afetados por essas imprevisibilidades listadas. Para essa lista de SKUs, executou-se 50 réplicas de simulação para cada um tendo em vista que os *lead times* são probabilísticos. A Tabela 11 exibe os resultados para todos os 20 SKUs. Observou-se um desvio médio percentual absoluto de cerca de 8% ao comparar-se o estoque médio real do período com o estoque médio resultante das simulações. Assim sendo,

considerou-se que o modelo de simulação abstraído das condições do sistema real de abastecimento são aproximações razoáveis.

Tabela 11 – Comparação do cenário base com dados reais

Código do SKU	Estoque Médio Real (Un)	Estoque Médio Simulado (Un)	Desvio Padrão do Estoque Médio Simulado (Un)	Desvio Percentual Absoluto Real vs Simulado
192241	328,05	429,31	32,39	30,87%
182284	161,48	138,13	8,66	14,46%
192592	254,05	226,53	10,27	10,83%
184561	70,67	62,76	3,00	11,19%
197978	78,42	72,46	2,35	7,59%
191185	85,48	76,80	4,11	10,16%
188737	327,15	295,49	20,87	9,68%
185302	487,32	524,27	28,28	7,58%
181669	1.096,09	1.195,86	84,92	9,10%
196649	64,24	61,38	2,55	4,45%
201757	195,26	209,58	13,05	7,33%
184564	149,52	158,11	8,49	5,75%
200483	79,50	83,16	3,82	4,60%
165861	392,18	429,84	46,91	9,60%
191186	84,86	87,82	3,95	3,49%
182754	34,43	32,81	2,87	4,70%
191921	44,55	46,37	5,02	4,10%
191870	54,49	52,51	6,82	3,63%
200676	58,99	59,71	3,49	1,22%
201543	157,39	156,82	7,20	0,36%

Fonte: Elaborado pelo autor

Modelo A de controle de estoques

Este modelo segue a mesma estrutura do modelo base, porém com algumas adaptações. O horizonte de dias para qual se realiza a previsão para o abastecimento do CD deixa de seguir um valor fixo de dias de acordo com a curva ABC do SKU e passa a ser calculado com base no *lead time* e no período de revisão. Outro ponto modificado é que não será mais levado em consideração um suposto estoque excedente das lojas para abater da necessidade de compra do CD. Além disso, adiciona-se um cálculo de estoque de segurança no CD de acordo com o FR desejado para o SKU.

Já o modelo de abastecimento do CD para as lojas também segue a mesma estrutura do modelo base, porém os parâmetros de estoque máximo e ponto de ressuprimento do SKU em cada loja deixam de ser considerados como uma entrada “fixa” no modelo e passam a ser recalculados diariamente. Passou a se adotar uma política de estoque base (S,S-1), de modo que o parâmetro S é calculado por meio de demanda média durante o ciclo de reposição (determinístico) acrescido de um estoque de segurança. A diferença do estoque de segurança da loja para o do CD é que ele é definido a partir de um CSL desejado de 99%, tendo em vista que a loja já tem o seu real nível de serviço penalizado quando o CD não possui estoque suficiente para abastecê-la.

Essas modificações feitas em relação ao modelo base são expressas nas seguintes relações matemáticas abaixo:

$$\text{Lead Time médio de entrega do fornecedor para o CD (dias): } LTm_{CD} \quad (76)$$

$$\text{Desvio padrão do Lead Time de entrega do fornecedor para o CD (dias): } \sigma_L \quad (77)$$

$$\text{Demanda média diária total até o dia d (un): } Dm_d \quad (78)$$

$$\text{Desvio padrão da demanda média diária total até o dia d (un): } \sigma_{D,d} \quad (79)$$

$$\text{Estoque de segurança desejado no CD no dia d (un) = } ES_{CD,d} = z_{CD,d} * \sigma_{R+L,CD,d} \quad (80)$$

$$\text{Coeficiente de segurança no CD no dia d = } z_{CD,d} = \text{equações [15 – 17]} \quad (81)$$

$$\text{Desvio padrão da demanda durante ciclo de reposição do CD no dia d = } \sigma_{T+L,CD,d} = \sqrt{(R + LTm_{CD}) * \sigma_{D,d}^2 + (\sigma_L * Dm_d)^2} \quad (82)$$

$$\text{Estoque alvo para reposição do CD no dia d (un) = } E_{AlvoCD,d} = F_{d,T+LTm} + ES_{CD,d} \quad (83)$$

$$\text{Período de revisão do estoque na loja k: } T_k = \begin{cases} 1, & \text{data} \neq \text{Sábado} \\ 2, & \text{data} = \text{Sábado} \end{cases} \quad (84)$$

$$\text{Demanda média diária na loja k até o dia d (un): } Dm_{k,d} \quad (85)$$

$$\text{Desvio padrão da demanda média diária na loja k até o dia d (un): } \sigma_{k,d} \quad (86)$$

$$\text{Estoque máximo do SKU na loja k no dia d: } S_{k,d} = Dm_{k,d} * (T_k + LT_k) + es_{k,d} \quad (87)$$

$$\text{Ponto de ressuprimento do SKU na loja k no dia d: } s_{k,d} = S_{k,d} - 1 \quad (88)$$

$$\text{Estoque de segurança desejado na loja k no dia d (un) = } es_{k,d} = z_k * \sigma_{T+L,k,d} \quad (89)$$

$$\text{Coeficiente de segurança na loja k = } z_k = z(F(z) = CSL) \quad (90)$$

$$\text{Desvio padrão da demanda durante ciclo de reposição da loja k no dia d = } \sigma_{T+L,k,d} = \sigma_{k,d} * (T_k + LT_k) \quad (91)$$

Modelo B de controle de estoques

O modelo alternativo B tem a mesma base do modelo A porém com uma única diferença: o estoque de segurança no CD passa a ser calculado com base em um CSL e não um FR. Para o modelo A, as fórmulas que determinam o coeficiente z do cálculo do estoque de segurança assumindo distribuição normal e um FR desejado estão descritas nas equações [15-17].

Esse método de cálculo do coeficiente z permite considerar um estoque de segurança negativo. Nesses casos, é como se planejasse que o estoque fosse acabar em algum momento de todos os ciclos de reposição. Consequentemente, o estoque de segurança calculado por um FR tende a ser menor que quando calculado com base em um CSL.

Entretanto, diante de uma simulação em que existem diversas incertezas e algumas simplificações, pode ser que o estoque de segurança calculado por um FR acabe gerando pedidos de compra com quantidades excessivamente pequenas que não permitam atingir os níveis de serviço desejado. Neste cenário, o modelo B pode vir a performar melhor.

Em termos das formulações matemáticas do modelo, a mudança que ocorreu foi a seguinte:

$$\text{Coeficiente de segurança no CD} = z_{CD} = z(F(z) = \text{CSL}) \quad (92)$$

Modelo C de controle de estoques

O modelo alternativo C também apresenta como base o modelo A, apenas mudando o método o qual se utiliza para calcular o estoque de segurança no CD, mais especificamente, no cálculo do desvio padrão que multiplica o coeficiente de segurança z .

O modelo A utiliza como base a variância da demanda, já o modelo C passa a utilizar como base a variância dos erros de previsão. A expectativa, conforme comentado na seção de revisão de literatura, é de que utilizando modelos de demanda com uma acurácia melhor do que simplesmente assumir demanda média, seja necessário manter um nível menor de estoque de segurança para se atingir o nível de serviço desejado. Isso ocorre tendo em vista que não seria necessário proteger o estoque para toda a variabilidade da demanda, mas sim apenas a variabilidade que não é capturada pelo respectivo modelo de previsão.

A formulação matemática para o cálculo do desvio padrão é a seguinte:

Desvio padrão do erro de previsão durante ciclo de reposição do CD no dia d =

$$\sigma_{R+L,CD,d} = \sqrt{(MSE_{T+L,d} + (\sigma_L * RMSE_{D,d})^2} \quad (92)$$

Onde:

$MSE_{T+L,d}$: *Mean Squared Error* da previsão de demanda calculada para a demanda agregada no ciclo de reposição médio ($T+LTm_{CD}$) até o dia d

$RMSE_{T+L,d}$: *Root Mean Squared Error* da previsão de demanda calculada diariamente até o dia d

Modelo D de controle de estoques

O modelo alternativo D utiliza uma mistura dos modelos B e C. Desse modo, ele também utiliza o desvio padrão dos erros de previsão (equação 92) ao invés do desvio padrão da demanda. A diferença é que o método de cálculo do coeficiente z é a mesma do modelo B (equação 91), por CSL, ao invés de seguir o método dos modelos A e C, por FR.

4.2.2 Coleta de dados e restrição do escopo

De acordo com os modelos conceituais definidos, é possível elencar quais os dados necessitam ser coletados para o desenvolvimento da simulação: histórico de vendas, histórico de estoques, histórico de funcionamento das lojas, base de produtos com seus respectivos atributos (custo médio unitário, fornecedor, período de revisão, lotes múltiplos de compra, status, curva ABC, categoria), base de parâmetros de reposição de lojas, histórico de pedidos de compra e histórico dos preços. A seguir serão descritos os motivos da necessidade desses dados e suas respectivas características. Além disso, o escopo deste trabalho será delimitado em diferentes dimensões: centros de distribuição, lojas, produtos e período.

Histórico de vendas

Os registros de vendas coletados foram do período de 01 de Novembro de 2018 a 31 de Outubro de 2021. Desse modo, é possível obter 3 anos de histórico. Esse histórico de vendas

foi coletado na granularidade diária e reflete a venda no nível SKU-Centro. Por “Centro”, entende-se a localização (loja ou CD) de onde ocorreu a saída de estoque para atender determinada venda. Por exemplo, vendas online são computadas como vendas do CD, a não ser que a mercadoria tenha sido retirada diretamente em uma loja. Desse modo, é possível analisar a demanda do ponto de vista de onde o estoque tem que estar localizado para atendê-la.

Histórico de estoques

O atual sistema ERP da empresa armazena apenas a situação atual do estoque na granularidade SKU-Centro. Armazenar o histórico diário de estoque no início ou fim do dia seria muito custoso em termos de capacidade de armazenamento, tendo em vista que seriam milhões de registros a cada dia. Entretanto, o histórico das movimentações físicas de entrada e saídas de estoque são armazenados no sistema, possibilitando a reconstrução do histórico do estoque a partir da atual posição e o histórico de movimentações.

Desse modo, foram coletadas as posições de estoque do final do dia 31 de Outubro 2021 na granularidade SKU-Centro e os seus respectivos históricos de movimentações físicas de estoque. O período de coleta desse histórico é o mesmo do histórico de vendas, ou seja, de 01 de Novembro de 2018 a 31 de Outubro de 2021.

O objetivo de se coletar o histórico de estoque é poder incluir nos modelos de previsão uma variável associada à *stockouts*, compatível com o método “*flagging*” apresentado na Tabela 3.

Base de atributos de produtos

Custo Médio Unitário: As informações sobre custos são necessárias para calcular o valor monetário do estoque, necessário para cálculo de indicadores como “Estoque Médio (R\$)”. Desse modo, foram coletados os valores de custo médio unitário dos SKUs como aproximação para transformar o estoque registrado em unidades em valores monetários.

Fornecedor: Um determinado SKU pode ter um ou mais fornecedores registrados, embora a maioria tenha apenas um único fornecedor. Para fins de simplificação, para os SKUs que possuem mais de um fornecedor registrado adota-se o fornecedor apontado como “regular”, ou seja, o fornecedor prioritário dentre todos os listados para aquele SKU.

Período de revisão: É o intervalo em dias entre as análises da necessidade de compra de um SKU. Normalmente, os SKUs de um mesmo fornecedor costumam ter o mesmo período de revisão para facilitar o gerenciamento e processo de compra dos mesmos.

Lotes múltiplos: Define de quantas em quantas unidades um SKU pode ser comprado. Esse valor pode variar de acordo com o fornecedor, caso o SKU possua mais de um fornecedor disponível, porém nestes casos adota-se o valor do fornecedor listado como “regular”.

Status: Indica se o SKU está ativo ou inativo. Produtos ativos significam que ainda necessitam ser comprados caso o modelo indique a necessidade, enquanto os produtos inativos estão fora de linha e não serão mais comprados.

ABC: Indica em qual faixa da curva ABC realizada pela Empresa o respectivo SKU se encontra.

Categoria: Esta informação serve para fins de estratificações de análises. Na realidade, consiste em 3 colunas diferentes: Grupo 3, Grupo 6, Grupo 9. Esses conceitos já foram explicados no capítulo de introdução.

Base de parâmetros de reposição de lojas

Esta base contém os atuais parâmetros de ponto de ressuprimento e estoque máximo de cada SKU em cada Loja. Além disso, também há o atributo de “Status”, que indica se o SKU está liberado para ser distribuído do CD até a respectiva loja. Nem todos os SKUs ativos para compra são liberados para serem distribuídos em todas as lojas.

Histórico dos pedidos de compra

Cada fornecedor possui um valor de “*lead time* esperado”, entretanto, esses dados não se mostraram muito confiáveis e carecem de uma rotina de atualização. Deste modo, para alimentar as simulações de modelos de estoques que envolvem *lead times* probabilísticos, é necessário ter um registro do histórico de entregas dos mesmos. Além disso, foram retirados *outliers* dessa base para não distorcer os resultados das simulações.

Histórico dos preços

Para a execução das simulações que envolvam modelos causais de previsão, é benéfico ter o histórico dos preços praticados para um SKU como tentativa de aumentar a acurácia do modelo. Com o histórico dos preços, é possível mensurar o efeito das variações nas vendas por conta de variações nos preços.

Restrição do escopo de Centros de Distribuição

Como explicado no capítulo de introdução, a Empresa possui 3 CDs na sua cadeia de abastecimento: um em Manaus, um em Porto Velho e um em Rio Branco. Entretanto, mais de 95% das compras são feitas diretamente para o CD de Manaus. Apesar da empresa denominar como Centro de Distribuição as instalações que possui em Porto Velho e em Rio Branco, na prática elas funcionam mais similarmente a simples armazéns de modo a acomodar produtos de grande porte (móveis, linha branca etc.) que esbarram em restrições de capacidade mais críticas nas lojas de seus respectivos Estados.

Portanto, optou-se por considerar neste trabalho apenas o CD de Manaus por sua expressividade na representatividade das operações da Empresa, assim também como maneira de simplificar num primeiro momento a abstração da cadeia de suprimentos para os modelos de simulação.

Restrição do escopo de Lojas

Como optou-se por não envolver os CDs de Porto Velho e de Rio Branco, também se optou por remover do trabalho as lojas que possuem produtos abastecidos por estes CDs. Entretanto, para fins de simplificação do esquema de simulação integrado entre lojas e CDs, optou-se por trabalhar apenas com as lojas de Manaus, que é onde fica a sede da Empresa.

Entre as lojas de Manaus, será desconsiderado o supermercado. Essa decisão foi tomada por se tratar de um centro que vende exclusivamente uma categoria de produtos completamente diferente das demais lojas e que envolve diferentes características, como data de validade dos alimentos, por exemplo.

Restrição do escopo de Produtos

Serão removidos do escopo deste trabalho tanto produtos inativos quanto produtos que possuam menos de 2 anos de histórico de vendas. Essa restrição de 2 anos ocorre tendo em vista que o ideal seria utilizar no mínimo 365 dias para calibrar a simulação, enquanto os 365 dias seguintes seriam utilizados para computar os indicadores decorrentes da mesma.

Além disso, no Pareto apresentado na Figura 3, observa-se que as duas categorias que mais faturaram em 2020 (Telefonia e Linha Branca) representaram cerca de 60% do total do faturamento da Empresa naquele ano. Deste modo, optou-se por restringir o escopo a essas duas categorias de maneira a simplificar o experimento, porém ainda mantendo uma porção relevante do faturamento da Empresa.

Restrição do escopo de Período

A base de dados de vendas e histórico de movimentações de estoque disponibilizada pela Empresa inicia-se apenas em Novembro de 2018 indo até Outubro de 2021. Deste modo, o período para o qual serão realizadas as simulações também será o mesmo citado anteriormente, computando os indicadores apenas nos 365 dias mais recentes. O histórico de vendas do produto que excede 365 dias é utilizado para calibrar a simulação, porém, tendo em vista que selecionamos produtos com no mínimo 2 anos de histórico, isto garante no mínimo 365 dias de calibração da simulação.

Tabela 12 – Descrição do escopo da simulação


Nº de CDs	1
Nº de Lojas	15
Nº de SKUs	249
Categorias dos SKUs	Linha Branca & Telefonia
Status dos SKUs (Em linha e Fora de Linha)	Apenas em Linha
Mínimo histórico de demanda necessário	2 anos
Faturamento nos últimos 36 meses (R\$)	~R\$ 905 milhões
Faturamento nos últimos 12 meses (R\$)	~R\$ 360 milhões
Representatividade do Faturamento Total da Empresa nos últimos 36 meses (%)	~12%
Representatividade do Faturamento Total da Empresa nos últimos 12 meses (%)	~15%

Fonte: Elaborado pelo autor

4.2.3 Modelos de previsão de demanda

Antes de desenvolver os modelos de demanda, optou-se primeiro por agregar as vendas de todos os SKUs e pontos de venda do escopo selecionado para se observar as características da série histórica.

Figura 26 – Série histórica de vendas agregadas dos SKUs



Fonte: Elaborado pelo autor

Na Figura 26 pode-se observar que a demanda claramente é sazonal e apresenta seus maiores picos próximos de ocasiões especiais de fim de ano, como *Black Friday* e Natal. Também é possível notar períodos de baixa demanda quando a grande maioria das lojas ficaram fechadas por conta da pandemia de COVID-19, como no segundo trimestre de 2020 e no primeiro bimestre de 2021, quando houve a considerada “segunda onda” do vírus em Manaus.

Outra maneira de se analisar a série temporal é realizando sua decomposição em 3 fatores: tendência, sazonalidade e resíduos. O processo de decomposição de uma série temporal foi descrito com mais detalhes na seção de revisão bibliográfica. Para realiza tal decomposição, utilizou-se a função `seasonal_decompose()` da biblioteca `statsmodels` da linguagem de programação *Python*, optando-se pela decomposição aditiva.

Na Figura 27 podemos notar que o componente de sazonalidade aparenta representar um período semanal. Entretanto, ao analisar a componente da tendência, é possível notar que

ela costumar alternar períodos de alta e de baixa dentro de um mesmo mês, provavelmente por conta de outras eventos que não foram identificados pela componente sazonal.

Figura 27 – Decomposição da série temporal das vendas agregadas dos SKUs



Fonte: Elaborado pelo autor

Para este estudo de simulação, foram desenvolvidos tanto modelos de previsão baseado somente em séries temporais como também modelos de demanda causais. Dentre os métodos univariados de previsão optou-se, além do algoritmo adaptado de média móvel comentado na seção de revisão dos processos atuais da Empresa, pelo método de suavização exponencial com tendência e sazonalidade (Holt-Winters) e pelo SARIMA, pelo fato de ambos os métodos levarem em conta séries temporais com sazonalidade. Já dentre os métodos causais, optou-se por utilizar o Método dos Mínimos Quadrados e *Random Forest*. Para os métodos

causais, realizou-se a seleção de variáveis analisando os métodos *stepwise*, LASSO e um método baseado no algoritmo *Random Forest*.

Holt-Winters

A formulação do modelo de previsão Holt-Winters foi enunciada nas equações [23-26]. O algoritmo foi desenvolvido através da utilização da função *ExponentialSmoothing()* da biblioteca *statsmodels* da linguagem de programação *Python*. A Figura 28 apresenta o pseudocódigo do algoritmo:

Figura 28 – Pseudocódigo do algoritmo Holt-Winters

```
def HoltWintersForecast(serie_historica, periodos, inicio_simulacao, fim_simulacao):

    """Função que recebe um dataframe com a série histórica de vendas de todos
    os SKUs e retorna o forecast para os próximos K períodos calculados
    durante todos os períodos dentro de um intervalo de simulação"""

    Para cada SKU da série histórica:
        Para cada data dentro do período da simulação:
            serie_treino = série histórica do início até a data selecionada
            modelo = aplicar ExponentialSmoothing(serie_treino,
                                                    trend="add",
                                                    seasonal="add",
                                                    seasonal_periods=7)

            lista_previsao = fazer previsão para os próximos K períodos
            soma_previsao = somar os valores da lista_previsao
            armazenar resultado na respectiva posição da série histórica
    retornar serie_historica
```

Fonte: Elaborado pelo autor

SARIMA

A formulação do modelo de previsão SARIMA foi enunciada na equação (28). Devido à grande quantidade de SKUs para os quais deseja-se fazer uma previsão, fica inviável analisar manualmente os gráficos e testes estatísticos para tentar determinar quais são os melhores parâmetros $(p, d, q) \times (P, D, Q)_s$ de cada SKU individualmente.

Para contornar esse problema, desenvolveu-se um algoritmo com base na função *auto_arima()* da biblioteca *pmdarima* da linguagem de programação *Python*. Resumidamente, esta função permite que seja configurado um range de valores para cada um dos parâmetros $(p, d, q) \times (P, D, Q)$ e treinar os modelos testando as combinações possíveis, retornando o modelo

que performou melhor de acordo com o critério de informação de Akaike (AIC). Entretanto, ainda é necessário passar como entrada da função o número de períodos do ciclo sazonal, que usaremos o valor de 7 dias.

Visando melhoria de performance computacional do algoritmo, é possível adotar o parâmetro *stepwise = True*, que usa o algoritmo de *stepwise* detalhado por Hyndman and Khandakar (2008) para identificar os parâmetros ótimos do modelo sem a necessidade de testar todas as combinações possíveis de parâmetros e possivelmente gerar um problema de *overfitting* no modelo.

A Figura 29 apresenta o pseudocódigo do algoritmo enquanto a Figura 30 ilustra o processo de otimização de parâmetros para um determinado SKU.

Figura 29 – Pseudocódigo do algoritmo SARIMA

```
def SARIMAForecast(serie_historica,periodos,inicio_simulacao,fim_simulacao):

    """Função que recebe um dataframe com a série histórica de vendas de todos
    os SKUs e retorna o forecast para os próximos K períodos calculados
    durante todos os períodos dentro de um intervalo de simulação"""

    Para cada SKU da série histórica:
        Para cada data dentro do período da simulação:
            serie_treino = série histórica do início até a data selecionada
            modelo = aplicar auto_arima(serie_treino,
                                      start_p=1, start_q=1, d=None,
                                      test='adf', #o parâmetro d é definido pelo
                                                  teste de Augmented Dickey-Fuller
                                      max_p=3, max_q=3,
                                      seasonal=True,
                                      m=7, #Ciclo sazonal
                                      start_P=1, start_Q=1, D=None,
                                      max_P=2, max_Q=2, max_D = 1,
                                      stepwise=True)
            lista_previsao = fazer previsão para os próximos K períodos
            soma_previsao = somar os valores da lista_previsao
            armazenar resultado na respectiva posição da série histórica
    retornar serie_historica
```

Fonte: Elaborado pelo autor

Figura 30 – Exemplo de otimização de parâmetros da função *auto_arima()*

```

Performing stepwise search to minimize AIC

Modelo Testado 1: AIC = 6687.785, Time=1.59 sec
.....
.....
.....
Modelo Testado N: AIC = 5851.852, Time=0.46 sec

Best model: ARIMA(2,0,0)(2,1,0)[7]
Total fit time: 24.973 seconds

```

Fonte: Elaborado pelo autor

Seleção de variáveis para os modelos causais de previsão de demanda

Para realizar a seleção das variáveis mais importantes para os modelos de previsão, partiu-se de uma lista pré-estabelecida de variáveis que foram julgadas com potencial de serem importantes a partir do comportamento da série de dados e conhecimentos sobre o ambiente do negócio. A Tabela 13 apresenta a descrição da lista de variáveis. Em resumo, foram combinadas variáveis com eventos de calendário (ex: dias da semana, meses do ano, Natal, *Black Friday* etc.) junto com variáveis que modelam o sortimento e os preços praticados.

Tabela 13 – Variáveis testadas nos modelos multivariados

Nome de variável	Valores	Descrição
[Seg-Dom]	binário	Uma variável diferente para cada um dos dias da semana
[Jan-Dez]	binário	Uma variável diferente para cada um dos meses do ano
Semana1DoMes	binário	Primeira semana de um mês
Semana2DoMes	binário	Segunda semana de um mês
DiaDasMaes_D-1	binário	Véspera de Dia das Mães
DiaDasMaes_W-1	binário	Semana anterior ao Dia das Mães
DiaDasMaes_W-2	binário	Penúltima semana anterior ao Dia das Mães
DiaDasMaes_W+1	binário	Semana posterior ao Dia das Mães
DiaDosPais_D-1	binário	Véspera de Dia dos Pais
DiaDosPais_W-1	binário	Semana anterior ao Dia dos Pais
DiaDosPais_W-2	binário	Penúltima semana anterior ao Dia dos Pais
DiaDosNamorados	binário	Dia dos Namorados

DiaDosNamorados_W-1	binário	Semana anterior ao Dia dos Namorados
DiaDosNamorados_W-2	binário	Penúltima semana anterior ao Dia dos Namorados
DiaDasCrianças	binário	Dia das Crianças
DiaDasCrianças_W-1	binário	Semana anterior ao Dia das Crianças
DiaDasCrianças_W-2	binário	Penúltima semana anterior ao Dia das Crianças
BlackFriday	binário	Dia da Black Friday
BlackFriday_Sab	binário	Dia posterior a Black Friday (sábado)
BlackFriday_Seg	binário	Segunda-feira posterior a Black Friday (cybermonday)
BlackFriday_W-1	binário	Semana anterior a Black Friday
Natal_23	binário	Dia 23 de Dezembro
Natal_Sabados	binário	3 últimos sábados anteriores ao Natal
Natal_W-1	binário	Semana anterior ao Natal
Natal_W-2	binário	Penúltima semana anterior ao Natal
Natal_W-3	binário	Antepenúltima semana anterior ao Natal
Natal_W+1	binário	Semana posterior ao Natal
COVID_Onda1	Números inteiros no intervalo [85,1]	Inicia em 23/Mar/2020 com valor 85 e decresce uma unidade até chegar ao valor 1 em 14/Jun/2020
COVID_Reabertura1	binário	Inicia em 15/Jun/2020 até 03/01/2021
COVID_Onda2	binário	Inicia em 04/Jan/2021 até 21/Fev/2021
COVID_Reabertura2	binário	Inicia em 22/Fev/2021 até 30/Jun/2021
Tendência	Número naturais não nulos	Inicia com valor 1 em 01/Nov/2018 e vai sendo incrementado em 1 unidade a cada dia
SortimentoDisponivel	Número naturais	Corresponde ao número de lojas abertas que possuem estoque do SKU. No caso da agregação dos SKUs, essa variável é somada na hora da agregação.
PreçoMédio	Números reais positivos	É o preço base (sem descontos) médio praticado
DescontoPercentual	Números reais no interval entre [0,1]	É o desconto percentual médio aplicado em relação ao preço base

Fonte: Elaborado pelo autor

Neste estudo, para fins de simplificação e evitar grande custo computacional, não foi feita uma seleção de variáveis de acordo com cada SKU em específico. A seleção de variáveis foi feita a partir da demanda agregada de todos os SKUs e assumiu-se a premissa de que estas também seriam relevantes quando replicadas para o modelo de um SKU em específico.

Foram utilizados 3 métodos diferentes para analisar e selecionar as variáveis: *stepwise*, *LASSO* e *Random Forest Feature Importance*. Os dois primeiros foram contemplados no

capítulo 2, enquanto o terceiro é obtido a partir do método *feature_importances_* da biblioteca *sklearn* do *Python* após treinar o modelo usando o algoritmo de *Random Forest*.

A opção por utilizar mais de um método foi tomada pelo fato de diferentes métodos retornarem diferentes listas de variáveis. Desse modo, é possível comparar as semelhanças e divergências entre os resultados de cada método e optar por um deles.

A Tabela 14 exhibe quais foram as variáveis selecionadas em cada um dos 3 métodos. No método *stepwise*, utilizou $p\text{-value} < 0.01$ como critério de inserção de uma variável no modelo e $p\text{-value} > 0.05$ como critério de exclusão. No método baseado em *Random Forest*, ele não retorna um número ótimo de variáveis, mas sim uma pontuação relativa de cada variável pela métrica de impureza decrescente média (Breiman et al., 1984) de maneira que a soma das importâncias de todas as variáveis seja 100%. Deste modo, optou-se por selecionar a quantidade de variáveis necessárias para se ter uma “importância” acumulada de 95%.

Analisando os resultados obtidos em cada um dos 3 métodos, é possível verificar que há bastante semelhanças entre eles, de maneira que:

- 28 variáveis não foram escolhidas por nenhum dos métodos
- 7 variáveis foram escolhidas por apenas 1 método
- 5 variáveis foram escolhidas por 2 métodos
- 12 variáveis foram escolhidas por todos os métodos

Optou-se por selecionar as variáveis que foram escolhidas por pelo menos 2 dos métodos.

Tabela 14 – Variáveis retornadas pelos métodos de seleção de variáveis

Nome de variável	Stepwise	LASSO	Random Forest	Selecionada?
Seg				Não
Ter				Não
Qua				Não
Qui				Não
Sex				Não
Sab	X	X	X	Sim
Dom	X	X	X	Sim
Jan	X	X		Sim
Fev	X			Não
Mar				Não
Abr				Não
Mai				Não

Jun				Não
Jul				Não
Ago				Não
Set				Não
Out	X			Não
Nov		X	X	Sim
Dez		X		Não
Semana1DoMes	X	X	X	Sim
Semana2DoMes	X	X	X	Sim
DiaDasMaes_D-1				Não
DiaDasMaes_W-1				Não
DiaDasMaes_W-2				Não
DiaDasMaes_W+1				Não
DiaDosPais_D-1				Não
DiaDosPais_W-1		X		Não
DiaDosPais_W-2				Não
DiaDosNamorados				Não
DiaDosNamorados_W-1				Não
DiaDosNamorados_W-2				Não
DiaDasCrianças				Não
DiaDasCrianças_W-1				Não
DiaDasCrianças_W-2				Não
BlackFriday	X	X		Sim
BlackFriday_Sab	X	X	X	Sim
BlackFriday_Seg	X	X		Sim
BlackFriday_W-1	X	X	X	Sim
Natal_23				Não
Natal_Sabados		X		Não
Natal_W-1				Não
Natal_W-2				Não
Natal_W-3				Não
Natal_W+1	X			Não
COVID_Onda1	X	X	X	Sim
COVID_Reabertura1		X	X	Sim
COVID_Onda2	X	X	X	Sim
COVID_Reabertura2	X			Não
Tendência	X	X	X	Sim
SortimentoDisponivel	X	X	X	Sim
PreçoMédio	X	X	X	Sim
DescontoPercentual	X	X	X	Sim

Fonte: Elaborado pelo autor

Método dos Mínimos Quadrados

O Método dos Mínimos Quadrados (MMQ), ou Mínimos Quadrados Ordinários (MQO) ou OLS (do inglês *Ordinary Least Squares*) teve sua formulação descrita na equação (29). O algoritmo foi desenvolvido através da utilização da função *OLS()* da biblioteca *statsmodels* da linguagem de programação *Python*. A Figura 31 apresenta o pseudocódigo do algoritmo.

Figura 31 – Pseudocódigo do algoritmo MMQ

```
def OLSForecast(serie_historica, periodos, inicio_simulacao, fim_simulacao):

    """Função que recebe um dataframe com a série histórica de vendas e das variáveis independentes
    de todos os SKUs e retorna o forecast para os próximos K períodos calculados durante todos
    os períodos dentro de um intervalo de simulação"""

    Para cada SKU da série histórica:
        Para cada data dentro do período da simulação:
            serie_treino_X = série histórica das variáveis independentes
                           do início até a data selecionada
            serie_treino_Y = série histórica da variável dependente
                           do início até a data selecionada
            serie_forecast_X = série temporal das variáveis independentes
                             do primeiro dia após a data selecionada
                             até atingir K dias
            remover variáveis que tenham desvio padrão = 0 na série de treino
            adicionar constante nas séries das variáveis independentes
            modelo = aplicar OLS(serie_treino_Y, serie_treino_X)
            lista_previsao = fazer previsão para os próximos K períodos
                           utilizando a serie_forecast_X
            soma_previsao = somar os valores da lista_previsao
            armazenar resultado na respectiva posição da série histórica
    retornar serie_historica
```

Fonte: Elaborado pelo autor

Random Forest

O modelo de *Random Forest*, descrito no capítulo 2, foi implementado através da função *RandomForestRegressor()* da biblioteca *sklearn* da linguagem de programação *Python*. A Figura 32 apresenta o pseudocódigo do algoritmo. A principal diferença dessa função para as outras é que ela é capaz de retornar apenas um período de previsão por vez, desse modo sendo necessário um *loop* para chamar a previsão diversas vezes até atingir os K períodos desejados.

Figura 32 – Pseudocódigo do algoritmo de regressão por *Random Forest*

```
def RandomForestForecast(serie_historica, periodos, inicio_simulacao, fim_simulacao):

    """Função que recebe um dataframe com a série histórica de vendas e das variáveis independentes
    de todos os SKUs e retorna o forecast para os próximos K períodos calculados durante todos
    os períodos dentro de um intervalo de simulação"""

    Para cada SKU da série histórica:
        Para cada data dentro do período da simulação:
            serie_treino_X = série histórica das variáveis independentes
                           do início até a data selecionada
            serie_treino_Y = série histórica da variável dependente
                           do início até a data selecionada
            serie_forecast_X = série temporal das variáveis independentes
                             do primeiro período após a data selecionada
                             até atingir K períodos
            modelo = RandomForestRegressor(n_estimators = 100).fit(serie_treino_X, serie_treino_Y)
            lista_previsao = []
            Para cada dia dentro do período de previsão k:
                forecast = fazer previsão do dia utilizando o respectivo índice de serie_forecast_X
                lista_previsao_diaria.append(forecast)
            soma_previsao = somar os valores da lista_previsao
            armazenar soma_previsao na respectiva posição da série histórica
    retornar serie_historica
```

Fonte: Elaborado pelo autor

4.3 RESULTADOS E DISCUSSÃO

Com os modelos de controle de estoque e de previsão de demanda desenvolvidos, segregou-se a análise de resultados em duas subseções. Na primeira, são discutidos os desempenhos dos modelos de previsão de demanda de maneira isolada, isto é, sem levar em consideração suas aplicações nos experimentos de simulação de controle de estoques.

Na segunda, são avaliados os resultados dos 25 cenários executados (combinação de 5 modelos de previsão x 5 modelos de controle de estoques) para cada um dos 249 SKUs do escopo a partir dos valores de FR realizados e estoque médio. Pelo fato de as simulações usarem valores de *lead time* probabilísticos, optou-se por realizar 50 réplicas por SKU para cada um dos 25 experimentos, totalizando 311.250 simulações.

4.3.1 Resultados dos modelos de previsão

Conforme descrito na delimitação do escopo do estudo, os desempenhos dos modelos foram avaliados nos 365 dias mais recentes da série histórica de dados para cada SKU, enquanto o período anterior foi utilizado apenas para treinar os modelos. Durante o período da série histórica avaliada, o modelo é retreinado diariamente e realiza uma previsão para k períodos a frente, onde k equivale ao período do ciclo de abastecimento daquele SKU (período da revisão periódica + *lead time* médio).

A métrica utilizada para comparar os modelos de previsão foi uma ponderação do MAPE pela demanda do SKU, apelidada de *weighed* MAPE (wMAPE), com o objetivo de possuir uma métrica capaz de avaliar os SKUs de maneira agregada. A métrica é calculada da seguinte maneira:

$$wMAPE = \frac{\sum_{SKU=1}^m \sum_{t=1}^{n=365-k} |D_{t,k} - F_{t,k}|}{\sum_{SKU=1}^m \sum_{t=1}^{n=365-k} D_{t,k}}$$

Onde:

$D_{t,k}$: Demanda total realizada nos k períodos a frente do período t

$F_{t,k}$: Previsão da demanda total nos k períodos a frente do período t

n : Total de períodos para qual é recalculada a previsão

m : Total de SKUs

A Tabela 15 representa os 5 algoritmos de previsão de demanda rankeados de acordo com seus respectivos wMAPEs. Também é exibida uma coluna com a média da métrica RMSE para todos os SKUs, tendo em vista que esta informação impactará nos cálculos dos estoques de segurança nos modelos de controle de estoques C e D.

Tabela 15 – Desempenho dos modelos de previsão

Nome do modelo	wMAPE	Média RMSE
<i>Random Forest</i>	14,66%	42,04
SARIMA	40,43%	116,08
Método dos Mínimos Quadrados Ordinários (MMQ)	46,85%	131,03
Método Base (baseado em média móvel)	48,83%	134,37
Suavização Exponencial (Holt-Winters)	84,04%	314,44

Fonte: Elaborado pelo autor

É possível observar que todos os modelos testados se demonstraram superiores ao modelo base, com exceção do método de Holt-Winters, que foi disparadamente o modelo com pior desempenho. Já o modelo de *Random Forest* obteve um desempenho bem acima dos demais. O ranqueamento dos algoritmos segue a mesma ordem para ambas as métricas avaliadas.

A hipótese de que modelos com variáveis externas performassem melhor que métodos univariados não se concretizou totalmente, tendo em vista que o SARIMA obteve uma melhor performance que o MMQ. Os resultados do MMQ podem ter sido bastante penalizados pelo fato da seleção de variáveis ter sido feita considerando a demanda agregada de todos os SKUs. Desse modo, ao replicar as variáveis para os modelos na granularidade de SKU, podem gerar casos de variáveis insignificantes que acabam atrapalhando a performance da previsão ou até mesmo a exclusão de uma variável que poderia ser importante para um SKU em específico. Apesar disso, o modelo de *Random Forest*, que também utiliza variáveis externas, foi o algoritmo de melhor desempenho, demonstrando ser um método mais robusto para a base de dados analisada.

Importante ressaltar também que a tendência da acurácia dos modelos é diminuir conforme se aumenta a granularidade da previsão. A acurácia dos modelos de previsão agregando por produto já não demonstrou ser tão alta, com a maioria dos modelos com wMAPE acima de 40%. Desse modo, neste estudo optou-se por não introduzir nos modelos de controle de estoques o uso da previsão de demanda na granularidade ‘SKU-Ponto de Venda’ justamente por conta da dificuldade e complexidade de se obter bons resultados para esta granularidade, com uma demanda ainda mais esparsa e intermitente.

4.3.2 Resultados das simulações de controle de estoques

Os 25 diferentes cenários foram avaliados segundo três métricas: estoque médio calculado em valores monetários e agregados para todos os SKUs; o *fill rate* realizado seguindo a mesma metodologia de cálculo da Empresa para agregar este indicador para todos os SKUs; e por fim, o percentual de simulações na qual o *fill rate* observado foi igual ou superior à meta imposta de acordo com a curva ABC. O objetivo de incluir esta terceira métrica é impedir que cenários que performam bem apenas majoritariamente para produtos de maior demanda sejam mascarados por conta da ponderação feita no momento de agregar o indicador.

Os resultados dessas métricas podem ser observados na Tabela 16, na qual optou-se por utilizar uma escala de cores para destacar os resultados. O cenário utilizado como *benchmark*, ou seja, aquele que desejamos superar, é o “Base x Média Móvel”.

Tabela 16 – Resultados dos cenários simulados

Modelo de controle de estoques x Modelo de previsão	Estoque Médio Total (R\$)	Desvio Padrão Estoque Total (R\$)	Fill Rate (%)	Desvio Padrão do Fill Rate (%)	Percentual de simulações com FR > Meta
Modelo Base x Média Móvel	R\$ 35.835.674,09	R\$ 366.077,08	83,67%	3,51%	47,37%
Modelo Base x Holt-Winters	R\$ 151.024.134,49	R\$ 1.763.594,03	93,49%	2,85%	88,25%
Modelo Base x SARIMA	R\$ 36.059.119,83	R\$ 425.223,77	83,95%	3,46%	52,41%
Modelo Base x MMQ	R\$ 33.780.451,23	R\$ 419.493,13	83,38%	3,56%	50,24%
Modelo Base x <i>Random Forest</i>	R\$ 32.392.990,31	R\$ 470.878,86	88,34%	3,08%	63,24%
Modelo A x Média Móvel	R\$ 25.931.009,00	R\$ 325.175,10	78,96%	4,39%	40,92%
Modelo A x Holt-Winters	R\$ 116.872.268,88	R\$ 1.411.685,92	89,34%	3,59%	84,88%
Modelo A x SARIMA	R\$ 25.144.087,07	R\$ 336.768,66	77,86%	4,19%	40,17%
Modelo A x MMQ	R\$ 23.981.066,73	R\$ 318.381,51	78,36%	4,14%	44,80%
Modelo A x <i>Random Forest</i>	R\$ 21.415.427,63	R\$ 391.530,48	82,77%	3,88%	55,57%
Modelo B x Média Móvel	R\$ 41.901.505,76	R\$ 461.969,06	89,03%	3,03%	83,35%
Modelo B x Holt-Winters	R\$ 155.375.266,85	R\$ 1.611.926,41	95,21%	2,36%	98,91%
Modelo B x SARIMA	R\$ 39.428.852,00	R\$ 459.524,77	88,18%	3,26%	81,63%
Modelo B x MMQ	R\$ 38.350.519,46	R\$ 436.146,15	87,89%	3,26%	79,03%
Modelo B x <i>Random Forest</i>	R\$ 34.349.193,57	R\$ 554.334,68	93,32%	2,67%	97,48%
Modelo C x Média Móvel	R\$ 35.095.475,30	R\$ 344.317,44	86,61%	3,52%	67,48%
Modelo C x Holt-Winters	R\$ 231.925.903,03	R\$ 1.611.860,07	95,09%	2,20%	97,24%
Modelo C x SARIMA	R\$ 34.804.017,29	R\$ 347.999,30	84,97%	3,60%	62,37%
Modelo C x MMQ	R\$ 38.121.556,77	R\$ 360.192,26	86,18%	3,51%	70,71%
Modelo C x <i>Random Forest</i>	R\$ 24.897.918,94	R\$ 464.524,50	85,05%	3,40%	71,51%
Modelo D x Média Móvel	R\$ 60.467.752,91	R\$ 426.541,06	94,85%	2,02%	96,47%
Modelo D x Holt-Winters	R\$ 243.657.568,27	R\$ 1.569.546,88	98,45%	0,90%	100,00%
Modelo D x SARIMA	R\$ 58.266.489,60	R\$ 459.470,44	94,58%	2,13%	96,91%
Modelo D x MMQ	R\$ 60.089.491,72	R\$ 429.929,19	94,47%	2,26%	94,88%
Modelo D x <i>Random Forest</i>	R\$ 36.994.468,28	R\$ 491.205,20	94,11%	2,68%	98,47%

Fonte: Elaborado pelo autor

Observa-se que todos os modelos de controle de estoques que utilizam Holt-Winters estão entre os cenários com maiores índices de FR. Entretanto, estes bons resultados ocorrem às custas de uma elevação nos níveis de estoques da ordem de 4 a 5 vezes maiores do que no cenário base, tornando-os inapropriados. Como discutido nas análises dos modelos de previsão de demanda, Holt-Winters foi o que apresentou pior desempenho, refletindo também no controle de estoques.

Desconsiderando o modelo de previsão de Holt-Winters, o Modelo A de controle de estoques foi o que apresentou com maior consistência os menores níveis de estoques, porém por outro lado, apresentou os piores níveis de FR. Isto confirma o ponto levantado durante a modelagem que, diante de uma simulação em que existem diversas incertezas e algumas simplificações, como por exemplo a não aderência da demanda de um SKU à distribuição normal, pode ser que o estoque de segurança calculado por um FR acabe gerando pedidos de compra com quantidades excessivamente pequenas que não permitam atingir os níveis de serviço desejado. Por conta disso, foi desenvolvido o modelo B, com o uso de CSL ao invés de FR para o cálculo do estoque de segurança e que de fato apresentou valores de FR superiores.

Os cenários envolvendo o Modelo D ficaram entre os maiores *fill rates*, porém também com um grande aumento nos níveis de estoques em relação ao cenário base (aumentos em torno de 70%). A exceção foi o cenário “Modelo D x *Random Forest*”, que junto do cenário “Modelo B x *Random Forest*”, foram os dois que estiveram entre os maiores níveis de FR sem grandes aumentos de estoque. Este fato corrobora com a afirmativa de que uma previsão de demanda precisa é um bom direcionador para resultados de controle de estoques, tendo em vista que o *Random Forest* foi o algoritmo com maior acurácia.

Com o intuito de definir o melhor entre os dois cenários, realizou-se dois testes de hipótese de comparação de médias assumindo variâncias desconhecidas e desiguais. Um teste foi realizado para o estoque médio e outro para o *fill rate*. O primeiro teste retornou $p\text{-value} < 0,001$ enquanto o segundo retornou $p\text{-value} = 0,84$.

Teste 1

$$H_0: \mu_{\text{Estoque Médio, D}} - \mu_{\text{Estoque Médio, B}} = 0$$

$$H_1: \mu_{\text{Estoque Médio, D}} - \mu_{\text{Estoque Médio, B}} > 0$$

Teste 2

$$H_0: \mu_{\text{FR, D}} - \mu_{\text{FR, B}} = 0$$

$$H_1: \mu_{\text{FR, D}} - \mu_{\text{FR, B}} > 0$$

Desse modo, é possível afirmar tanto que o estoque médio do “Modelo D x *Random Forest*” é maior que o estoque médio do “Modelo B x *Random Forest*” para uma significância de 0,1% quanto que não há evidência estatística de que o FR do modelo D é maior que do

modelo B para uma significância de 5%. Mesmo assim, ainda se julga que o modelo “Modelo D x *Random Forest*” seja o ideal. Isso se dá pelo motivo do modelo de controle de estoques D considerar o estoque de segurança com base na variabilidade dos erros de previsão. Esse método dá margem para trabalhar-se ainda mais na acurácia do modelo de previsão e consequentemente permitir manter níveis de estoque de segurança menores do que os atuais.

Por fim, para confirmar que o modelo escolhido é superior ao cenário base, replicam-se os testes de hipótese feitos anteriormente alterando o “Modelo B x *Random Forest*” por “Modelo Base x Média Móvel”. Ambos os testes retoranam $p\text{-value} < 0.001$, ou seja, o modelo selecionado como ideal apresenta tanto estoque médio quanto FR maiores que no cenário base. Apesar do modelo proposto representar um aumento de cerca de 3% no estoque médio, ele também aumenta em pouco mais de 10% o FR e em mais de 50% o número de simulações que atingiram um FR maior que a meta estipulada para aquele SKU.

4.3.3 Revisão dos processos

A adoção do cenário “Modelo D x *Random Forest*” teria um impacto benéfico para os processos da Empresa. Isso ocorreria por conta da redução de necessidade de intervenção na calibração dos parâmetros, que hoje ocorre totalmente de maneira reativa. Além disso, a modelagem do algoritmo de *Random Forest* utilizando variáveis que capturam efeitos de sazonalidade e de *stockout* reduzem a quantidade de tomada de decisões muitas vezes arbitrárias nas questões envolvendo o abastecimento e reposição de estoques em períodos de alta sazonalidade e/ou com promoções.

Os dados necessários para processamento e modelagem do algoritmo de previsão de demanda já são de fácil acesso na Empresa, o que não implicaria em novas pesquisas ou desenvolvimentos internos. Todo o trabalho de pré-processamento dos dados e execução dos scripts que geram as recomendações de compra pode ser tratado pela equipe de *Data Science*, assim como o fluxograma do Apêndice A demonstra. A única mudança no fluxo seria quanto ao uso das informações sobre promoções futuras planejadas pela equipe de marketing. Essas informações deveriam ser repassadas para a equipe de *Data Science* ou cadastradas no ambiente SAP para que fosse possível consumir esses dados no algoritmo de previsão de demanda.

5 CONCLUSÕES

Este capítulo trata do fechamento do projeto de formatura. São apresentadas uma síntese do que foi realizado, as limitações do projeto e os desdobramentos e oportunidades para a Empresa.

5.1 SÍNTESE

A Empresa abordada neste projeto figura entre os principais varejistas da Região Norte. O ramo do varejo, conforme apontado pela literatura, tem se tornado um ambiente cada vez mais competitivo de maneira que manter um controle eficiente de estoques é essencial para os resultados da operação. Modelos ativos de controle de estoques tendem a desempenhar melhor que modelos reativos, principalmente em cenários onde a demanda não é estacionária, podendo ser influenciada por diversos fatores tanto internos quanto externos à Empresa. Neste contexto, a previsão de demanda também se torna essencial para um controle de estoques eficiente.

O projeto teve como objetivo revisar os modelos de previsão de demanda e controle de estoques da Empresa, tanto do estoque central quanto das lojas, de maneira a propor um método alternativo com desempenho superior de acordo com indicadores apropriados da operação, como estoque médio e *fill rate*. O método empregado para isso foi a revisão dos processos de compras e distribuição, incluindo mapeamentos de processos na notação BPMN e diagnóstico dos principais problemas. Posteriormente, seguiu-se a metodologia de simulação proposta por Banks *et al* (1998) para avaliar os novos modelos de previsão de demanda e controle de estoques em questão.

Os modelos de controle de estoques e suas simulações foram desenvolvidos utilizando *Excel* e VBA, além de *Python* para implantar os algoritmos de previsão de demanda. Foram desenvolvidos 5 modelos de controle de estoques e 5 modelos de previsão de demanda, totalizando 25 combinações de experimentos simulados. Uma dessas combinações foi denominada de “cenário base” e utilizou os atuais modelos de previsão de demanda e controle de estoques da Empresa. A validação do projeto de simulação desenvolvido foi feita utilizando os resultados do cenário base e comparando com dados reais da Empresa para o mesmo período e grupo de SKUs.

Os modelos de controle de estoques consideram revisão periódica, *lead times* probabilísticos e integração entre o CD e as lojas, de maneira que os pedidos de reposição de estoque das lojas são realizados apenas caso o CD não esteja com falta de estoque do respectivo SKU. Estes modelos de controle de estoques diferenciam-se no cálculo de estoque de segurança, alguns

considerando variabilidade da demanda e outros a variabilidade dos erros de previsão. Variou-se também a definição do coeficiente de segurança, ora sendo calculado por meio do FR desejado, ora pelo CSL.

Para os modelos de previsão de demanda, foram considerados tanto modelos univariados quanto modelos multivariados, também chamados de modelos causais. Para esse segundo tipo de modelo, foi necessário realizar um estudo para selecionar as variáveis mais importantes. Foram utilizados os métodos *stepwise*, LASSO e *Random Forest feature importance*.

Após a simulação dos experimentos, constatou-se que a combinação ideal foi o controle de estoques D associado com a previsão feita por *Random Forest*. Esse modelo de controle de estoques considerava o estoque de segurança calculado com base na variabilidade do erro de previsão de demanda e em um CSL desejado. Já o *Random Forest* foi o algoritmo de previsão de demanda com melhores desempenhos segundo as métricas RMSE e wMAPE.

Em comparação ao cenário base, o melhor método representou um aumento no estoque médio de cerca de 3%, porém com aumento de mais de 10% no *fill rate* agregado realizado e um aumento de 50% na probabilidade de um SKU atingir sua meta de FR estipulada de acordo com a curva ABC.

5.2 LIMITAÇÕES

O projeto foi executado para um escopo reduzido de produtos pertencentes às categorias mais relevantes da Empresa (Linha Branca e Telefonia) e somente para as lojas de Manaus, que é o principal polo de atuação do varejista. Desse modo, recomenda-se que antes de implementar os modelos de previsão de demanda e controle de estoques propostos, sejam testadas simulações considerando todo escopo de produtos da empresa e as lojas de outras cidades e regiões além de Manaus. Com esses testes, haveria uma maior garantia de boa performance dos modelos para toda a cadeia de suprimentos da Empresa.

Além disso, não se abordou neste projeto o dilema da previsão de vendas para produtos com pouco histórico de vendas, tornando o processo de previsão ainda mais difícil. Eventualmente poderiam ser adotadas estratégias específicas de modelagem de previsão de demanda para os casos de pouco histórico.

O modelo base simulado apresentou muita dificuldade em ter seus resultados validados. A Empresa é cercada de diversas incertezas, seja em *lead time*, seja na disponibilidade de estoque nos fornecedores, seja no alto nível de interferência manual que os funcionários da Empresa empregam na sugestão de pedidos de compra para o CD ou reposição de lojas.

Por fim, a capacidade computacional da máquina utilizada para desenvolvimento das simulações acabou sendo uma restrição no momento de testá-las. Por conta do alto tempo de execução, não foi possível testar mais do que 50 réplicas por SKU por experimento. Além disso, o alto custo computacional também guiou a decisão por não utilizar um modelo de controle de estoque ativo para o problema do estoque das lojas, mantendo esse tipo de modelo apenas para pedidos de compra para o estoque central.

5.3 DESDOBRAMENTOS E OPORTUNIDADES

Com um modelo de controle de estoques mais eficiente, além de melhorar os resultados da Empresa, os funcionários responsáveis pelos processos de compra podem se apoiar numa metodologia mais fundamentada e assertiva, que não exige tanto tempo de revisão e intervenção manual principalmente em períodos de alta incerteza da demanda, como tinha sido diagnosticado na revisão dos processos.

Embora não se tenha utilizado um modelo ativo para a reposição de estoque das lojas, a metodologia empregada já permite calcular parâmetros de estoque máximo e ponto de ressuprimento de maneira mais confiável, sem tantas decisões arbitrárias que tomam tempo em excesso dos funcionários responsáveis pelo processo de atualização da grade de referência de estoques máximos e mínimos.

Apesar deste projeto ter utilizado apenas um escopo reduzido de SKUs, já foi possível mapear um ganho significativo em relação aos métodos usualmente empregados. Há ainda oportunidades de melhorias, como explorar melhor a seleção de variáveis dos modelos causais de previsão, que é o caso do *Random Forest*, algoritmo de melhor desempenho dentre os testados. Uma alternativa que poderia aumentar a acurácia da previsão seria testar a seleção de variáveis de acordo com a categoria do produto, para depois generalizar para os SKUs da respectiva categoria.

Por fim, os desdobramentos deste projeto servirão de subsídio para as ações tomadas durante o restante do serviço de consultoria prestado à Empresa, que foca em desenvolver soluções de tecnologia para melhorar as decisões de abastecimento dela. Um próximo passo compreende a revisão da dinâmica de S&OP (*Sales & Operations Planning*) da Empresa, de maneira a integrar às reuniões de planejamento os dados e previsões gerados pelos modelos, os quais podem sofrer interferências manuais por parte dos gestores.

REFERÊNCIAS

- AMARAL, Fernando. **Séries temporais e análises preditivas**. 2018. 154 slides.
- ARNOLD, Tony et al. **Introduction to materials management**. Pearson, 2016.
- ARUNRAJ, Nari Sivanandam; AHRENS, Diane. A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. **International Journal of Production Economics**, v. 170, p. 321-335, 2015.
- BANKS, Jerry. Principles of simulation. **Handbook of simulation**, v. 12, p. 3-30, 1998.
- BIAZZI, Jorge. **Indicadores de desempenho em atendimento e estoques**. 2019. 64 slides.
- BIJVANK, Marco; VIS, Iris FA. Lost-sales inventory theory: A review. **European Journal of Operational Research**, v. 215, n. 1, p. 1-13, 2011.
- BOULAKSIL, Youssef. Safety stock placement in supply chains with demand forecast updates. **Operations Research Perspectives**, v. 3, p. 27-31, 2016.
- BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE C. J. **Classification and regression trees**, Wadsworth International Group, Belmont, California, 1984
- CORSTEN, Daniel; GRUEN, Thomas. Desperately seeking shelf availability: an examination of the extent, the causes, and the efforts to address retail out-of-stocks. **International Journal of Retail & Distribution Management**, 2003.
- CHOPRA, Sunil; REINHARDT, Gilles; DADA, Maqbool. The effect of lead time uncertainty on safety stocks. **Decision Sciences**, v. 35, n. 1, p. 1-24, 2004.
- CRUZ, Bruno. **Revisão do processo de reposição de estoques nas lojas de uma rede de franquias de roupas e acessórios infantis**. 105 f. Trabalho de Conclusão de Curso – Escola Politécnica da Universidade de São Paulo, São Paulo, 2019
- DEKKER, Mark; VAN DONSELAAR, Karel; OUWEHAND, Pim. How to use aggregation and combined forecasting to improve seasonal demand forecasts. **International Journal of Production Economics**, v. 90, n. 2, p. 151-167, 2004.
- DO REGO, José Roberto; DE MESQUITA, Marco Aurélio. Demand forecasting and inventory control: A simulation study on automotive spare parts. **International Journal of Production Economics**, v. 161, p. 1-16, 2015.
- EHLERS, Ricardo S. Análise de séries temporais. **Laboratório de Estatística e Geoinformação. Universidade Federal do Paraná**, v. 1, p. 1-118, 2007.
- ERUGUZ, Ayse Sena et al. A comprehensive survey of guaranteed-service models for multi-echelon inventory optimization. **International Journal of Production Economics**, v. 172, p. 110-125, 2016.

GARCIA, Eduardo et al. **Gestão de estoques: otimizando a logística e a cadeia de suprimentos**. Editora E-papers, 2006.

GONÇALVES, João NC; CARVALHO, M. Sameiro; CORTEZ, Paulo. Operations research models and methods for safety stock determination: A review. **Operations Research Perspectives**, p. 100164, 2020.

GUPTA, Anshuman; MARANAS, Costas D. Managing demand uncertainty in supply chain planning. **Computers & chemical engineering**, v. 27, n. 8-9, p. 1219-1227, 2003.

HUANG, Tao; FILDES, Robert; SOOPRAMANIEN, Didier. The value of competitive information in forecasting FMCG retail product sales and the variable selection problem. **European Journal of Operational Research**, v. 237, n. 2, p. 738-748, 2014.

HYNDMAN, Rob J. **Forecasting time series using R**. Disponível em: <<https://robjhyndman.com/talks/MelbourneRUG.pdf>>. Acesso em: 04 jul. 2021.

JAMES, Gareth et al. **An introduction to statistical learning**. New York: springer, 2013.

JONSSON, Patrik; MATTSSON, Stig-Arne. Advanced material planning performance: a contextual examination and research agenda. **International Journal of Physical Distribution & Logistics Management**, 2016.

JONSSON, Patrik; MATTSSON, Stig-Arne. An inherent differentiation and system level assessment approach to inventory management. **The International Journal of Logistics Management**, 2019.

KELLA, Rajesh; AGROGIANNIS, Christos. **Inventory Optimization as a Business Advantage**. 2016. Tese de Doutorado.

KOLASSA, Stephan. Evaluating predictive count data distributions in retail sales forecasting. **International Journal of Forecasting**, v. 32, n. 3, p. 788-803, 2016.

LEWIS, Jayne C.; NAIM, Mohamed M.; TOWILL, Denis R. An integrated approach to re-engineering material and logistics control. **International Journal of Physical Distribution & Logistics Management**, 1997.

LOUREIRO, Ana LD; MIGUÉIS, Vera L.; DA SILVA, Lucas FM. Exploring the use of deep neural networks for sales forecasting in fashion retail. **Decision Support Systems**, v. 114, p. 81-93, 2018.

LOKAD. **Mitigating the stock-out bias on forecasts**. 2016. Disponível em: <https://www.lokad.com/salecast-stockout-bias-on-forecasts/Pitfalls_of_stockout_data_integration_1>. Acesso em: 04 jul. 2021.

LUSTOSA, Leonardo; MESQUITA, Marco A.; OLIVEIRA, Rodrigo J. **Planejamento e controle da produção**. Elsevier Brasil, 2008.

NAHMIAS, Steven; CHENG, Ye. **Production and operations analysis**. New York: McGraw-hill, 2009.

POHLMAN, John T.; LEITNER, Dennis W. **A comparison of ordinary least squares and logistic regression**. 2003.

SANTORO, Miguel Cezar; FREIRE, Gilberto. Análise comparativa entre modelos de estoque. **Production**, v. 18, n. 1, p. 89-98, 2008.

SILVER, Edward Allen et al. **Inventory management and production planning and scheduling**. New York: Wiley, 1998.


SIMCHI-LEVI, David et al. **Designing and managing the supply chain: concepts, strategies and case studies**. Tata McGraw-Hill Education, 2008.


STEEMAN, Michiel. **The power of supply chain finance: How companies can apply collaborative finance models in their supply chain to mitigate risks and reduce costs**. Hogeschool Windesheim, 2014.

WHYBARK, D. Clay; WILLIAMS, J. Gregg. Material requirements planning under uncertainty. **Decision sciences**, v. 7, n. 4, p. 595-606, 1976.

ZIPKIN, Paul. Old and new methods for lost-sales inventory systems. **Operations Research**, v. 56, n. 5, p. 1256-1263, 2008.

APÊNDICE A – Fluxograma do Processo de Compras





APÊNDICE B – Fluxograma do Processo de Abastecimento de Lojas

