

UNIVERSIDADE DE SÃO PAULO
ESCOLA POLITÉCNICA
DEPARTAMENTO DE ENGENHARIA MECATRÔNICA

CÉSAR SEO TAKOSE
GUILHERME WATANABE IWABUCHI

**CIÊNCIA DOS DADOS APLICADA AO PLANEJAMENTO DE
DEMANDA**

TRABALHO DE CONCLUSÃO DE CURSO

SÃO PAULO
2021

CÉSAR SEO TAKOSE
GUILHERME WATANABE IWABUCHI

**CIÊNCIA DOS DADOS APLICADA AO PLANEJAMENTO DE
DEMANDA**

Trabalho de Conclusão de Curso apresentado ao
Departamento de Engenharia Mecatrônica da Universidade
de São Paulo, como requisito parcial para a obtenção do
título de Engenheiro.

Orientador: Felipe Miguel Pait
Escola Politécnica da USP

SÃO PAULO
2021

Este trabalho é dedicado às nossas famílias.

AGRADECIMENTOS

Primeiramente, às nossas famílias, que nos forneceram todo o apoio necessário durante a jornada.

Ao professor Felipe Miguel Pait, pela orientação, incentivo e confiança.

À Escola Politécnica da Universidade de São Paulo e a todos os seus funcionários, por proporcionarem um ambiente no qual crescemos pessoal e academicamente.

Aos colegas de turma da Mecatrônica, pela amizade e companheirismo durante os anos de graduação.

Às empresas pelos dados fornecidos, que possibilitaram a elaboração deste projeto e aos especialistas com quem conversamos, pelo direcionamento proporcionado.

"The future belongs to those who prepare for it today."

- Malcolm X

RESUMO

Este estudo apresenta a aplicação de métodos de previsão de demanda para desenvolvimento de políticas de reposição, no contexto de empresas ingressantes no *e-commerce*. Para as empresas estudadas, foram realizadas previsões de demanda a nível de *SKU* e a partir dessas previsões foram sugeridas ações de reposição para cada um dos *SKU*'s. Os modelos de previsão explorados foram o ARIMA e a suavização exponencial. As políticas de reposição foram baseadas em modelos de revisão periódica e do sistema mín-máx.

Palavras-chave: previsão de demanda, política de reposição, *e-commerce*

ABSTRACT

This study shows the application of forecasting methods in order to develop inventory policies for companies entering the *e-commerce*. For the studied companies, forecasting methods were applied to generate predictions for each *SKU* and from these predictions actions regarding the inventory were suggested for each *SKU*. The forecasting methods explored in this study were ARIMA and exponential smoothing. The inventory policies were developed based on periodic review models and the min-max system.

Keywords: demand forecast, inventory policy, *e-commerce*

LISTA DE FIGURAS

Figura 1 – Metodologia de um projeto de ciência de dados	11
Figura 2 – Método de revisão periódica para um único item	22
Figura 3 – Histórico de vendas de produtos notáveis ¹	25
Figura 4 – Análise por sabor: distribuição do faturamento (à esquerda) e histórico de vendas (à direita)	26
Figura 5 – Curva ABC	26
Figura 6 – Movimentações de estoque	26
Figura 7 – Detecção de <i>outliers</i>	28
Figura 8 – <i>Walk Forward Validation</i>	29
Figura 9 – Escolhas dos parâmetros para suavização exponencial simples e dupla .	29
Figura 10 – Simulação da política de revisão periódica	31
Figura 11 – Comparação entre estoque real e estoque simulado por revisão periódica	32
Figura 12 – Simulação da política mín-máx	33
Figura 13 – Comparação entre estoque real e estoque simulado por mín-máx	34
Figura 14 – Simulação da política mín-máx com cálculo alternativo de Q	34
Figura 15 – Comparação dos custos de estoque praticado e simulado para a Empresa 1	38
Figura 16 – Simulações para a Empresa 2	39
Figura 17 – Comparações com o estoque real para a Empresa 2	40
Figura 18 – Comparação dos custos de estoque praticado e simulado para a Empresa 2	41
Figura 19 – Simulações para a Empresa 3	42
Figura 20 – Comparações com o estoque real para a Empresa 3	43

LISTA DE TABELAS

Tabela 1 – Exemplos de perguntas para pesquisa	2
Tabela 2 – Resultados do <i>Walk Forward Validation</i> para a Empresa 1	30
Tabela 3 – Testes dos modelos para a Empresa 1	30
Tabela 4 – Resultados dos testes para a Empresa 1	36
Tabela 5 – Resultados por SKU da Empresa 1	37
Tabela 6 – Resultados dos testes para a Empresa 2	39
Tabela 7 – Resultados por SKU da Empresa 2	41
Tabela 8 – Resultados complementares por SKU da Empresa 1	49
Tabela 9 – Testes dos modelos de previsão Empresa 1	50
Tabela 10 – Resultados complementares por SKU da Empresa 2 parte 1	51
Tabela 11 – Resultados complementares por SKU da Empresa 2 parte 2	52
Tabela 12 – Testes dos modelos de previsão Empresa 2	53
Tabela 13 – Resultados por SKU da Empresa 3	54
Tabela 14 – Resultados complementares por SKU da Empresa 3	55
Tabela 15 – Testes dos modelos de previsão Empresa 3	56

LISTA DE ABREVIATURAS E SIGLAS

ACS	Análise da Cadeia de Suprimentos
ARIMA	Auto-Regressivo Integrado de Médias Móveis
BDAN	Big Data voltado para análise de negócios
GCS	gestão de cadeia de suprimentos
MLP	Perceptron Multicamadas
SARIMA	Auto-Regressivo Integrado de Médias Móveis Sazonal
<i>SKU</i>	<i>Stock Keeping Unit</i>

SUMÁRIO

1 – INTRODUÇÃO	1
1.1 CONTEXTUALIZAÇÃO	1
1.2 DISCUSSÃO COM ESPECIALISTAS	4
1.3 REVISÃO BIBLIOGRÁFICA	6
1.3.1 Estado da Arte	6
2 – REQUISITOS	10
3 – METODOLOGIA	11
4 – TEORIA	14
4.1 PREVISÃO DE DEMANDA	14
4.1.1 Suavização Exponencial	14
4.1.1.1 Suavização Exponencial Simples	14
4.1.1.2 Suavização Exponencial Dupla	15
4.1.1.3 Suavização Exponencial Tripla	15
4.1.2 Modelo SARIMAX	16
4.1.2.1 Modelo Auto-regressivo (AR)	16
4.1.2.2 Modelo de Médias Móveis (MA)	16
4.1.2.3 Modelo Auto-regressivo de Médias Móveis (ARMA)	17
4.1.2.4 Modelo Auto-regressivo Integrado de Médias Móveis (ARIMA)	17
4.1.2.5 ARIMA Sazonal (SARIMA)	17
4.1.2.6 SARIMA com variáveis externas (SARIMAX)	17
4.2 POLÍTICA DE REPOSIÇÃO	18
4.2.1 Método do ponto de pedido com demanda constante	19
4.2.2 Método do ponto de pedido com demanda incerta	20
4.2.3 Método prático: sistema Mín-Max	21
4.2.4 Método de revisão periódica para um único item	21
4.2.5 Método de revisão periódica para um conjunto de itens	22
4.2.6 Discussão sobre os métodos	23
5 – DESENVOLVIMENTO DO PROJETO	24
5.1 REQUERIMENTOS DOS DADOS	24
5.2 COLETA DOS DADOS	24
5.3 ENTENDIMENTO DOS DADOS	25
5.4 PREPARAÇÃO DOS DADOS	27
5.5 MODELAGEM	27

5.5.1	Previsão de Demanda	27
5.5.2	Política de Reposição	30
5.5.2.1	Revisão Periódica	31
5.5.2.2	Acompanhamento constante	32
6	– RESULTADOS	36
6.1	Empresa 1	36
6.2	Empresa 2	39
6.3	Empresa 3	41
7	– CONCLUSÃO	44
7.1	TRABALHOS FUTUROS	44
7.2	CONSIDERAÇÕES FINAIS	45
	Referências	46
	Apêndices	48
	APÊNDICE A – Resultados extras	49
A.1	Empresa 1	49
A.2	Empresa 2	51
A.3	Empresa 3	54

1 INTRODUÇÃO

1.1 CONTEXTUALIZAÇÃO

Na última década, houve um crescimento explosivo na quantidade de dados produzida mundialmente, contribuindo para o desenvolvimento do conceito de *Big Data*. Existem diversas propostas de definição para o termo, mas uma de particular interesse foi sugerida em (MAURO; GRECO; GRIMALDI, 2016), num artigo em que os autores analisaram o uso de '*Big Data*' através da literatura e tentaram propor uma definição amplamente aceita. Os autores explicaram *Big Data* como o ativo de informação que necessita de tecnologias e métodos analíticos específicos para ser transformado em valor, dados seus elevados graus de volume, velocidade e variedade. Entretanto, mais importantes do que a definição, são as oportunidades que surgem a partir do *Big Data*. A quantidade de dados disponível atualmente permite o avanço de estudos nas mais diversas áreas do conhecimento. Neste trabalho em particular, o foco foi direcionado em como o *Big Data* voltado para análise de negócios (BDAN) pode contribuir para o aprimoramento da gestão de cadeias de suprimentos (GCS).

Algumas razões motivaram a escolha descrita acima. Primeiramente, os autores deste trabalho acreditam que há valor na aplicação do conhecimento acadêmico adquirido durante a graduação em áreas que não necessariamente são estritamente acadêmicas, como no mundo dos negócios. Além disso, há um grande interesse das empresas no desenvolvimento da tecnologia da informação em logística motivado pela obtenção de uma vantagem competitiva, assim como indicado em (HAZEN; BYRD, 2012). Por fim, os autores acreditam que o desenvolvimento de um trabalho que envolve conhecimentos analíticos, BDAN, logística e GSC é um projeto desafiador, mas, acima de tudo, entusiasmante.

As possíveis contribuições de BDAN para GSC são inúmeras e, talvez, impossíveis de serem todas desenvolvidas em um único trabalho. Logo, foi necessário afunilar a região de interesse do estudo para enfim definir o tema do trabalho. Dois artigos foram utilizados para auxiliar nessa tarefa.

No primeiro, (WALLER; FAWCETT, 2013), os autores discutiram oportunidades nas quais ciência de dados, análises preditivas e *Big Data* podem contribuir para o desenvolvimento de pesquisas relacionadas às cadeias de suprimentos. Na Tabela 1, foram sugeridos exemplos de perguntas de pesquisas através da relação entre três fontes de dados - vendas, consumidor, local e hora - com três áreas da cadeia de suprimentos - gestão de inventário, gestão do transporte e gestão do relacionamento entre consumidor e fornecedor.

No segundo, (WANG et al., 2016), os autores analisaram como o uso de BDAN pode melhorar a tomada de decisões no campo de logística e cadeia de suprimentos. Os autores nomearam essa relação como Análise da Cadeia de Suprimentos (ACS) e fazem

Tabela 1 – Tradução livre dos exemplos de perguntas para pesquisa.

Tipos de dados	Gestão de estoque	Gestão de transporte	Gestão de relacionamento com clientes e fornecedores
Vendas	Como dados de vendas juntamente com dados detalhados de clientes podem ser usados para melhorar a gestão de estoque tanto em termos de previsão quanto em relacionar produtos a compradores ideais?	Como dados de vendas mais recentes podem ser usados para redirecionar entregas em trânsito? Como os dados de vendas em conjunto com dados detalhados de clientes podem ser usados para melhorar a eficiência e efetividade de operações feitas em trânsito?	Como dados de vendas mais granulares das diversas fontes existentes podem ser usados para melhorar a transparência e a confiança entre parceiros de negócios?
Consumidores	Como dados de reconhecimento facial para identificação de consumidores, detecção de emoções e dados de rastreamento ocular podem ser usados para determinar em quais locais específicos da prateleira os produtos devem ser colocados	Como preferências de entrega advindas de compras <i>on-line</i> podem ser usadas para auxiliar nas decisões sobre modos de transporte e escolha de operadores?	Como os sentimentos de consumidores sobre produtos, baseado em " <i>Likes</i> ", " <i>Tweets</i> " e avaliações podem ser usados para colaborar em previsões?
Localização e tempo	Como dados de sensores usados para detectar locais em lojas podem ser usados para melhorar a gestão de estoque, incluindo decisões sobre propagandas departamentais?	Como dados de sensores em centros de distribuição podem ser usados para antecipar necessidades de transporte	Como dados de localização e <i>time-stamp</i> dos consumidores podem ser usados para auxiliar em decisões sobre sortimento colaborativo e propagandas?

Fonte: (WALLER; FAWCETT, 2013)

uma revisão da literatura sobre trabalhos relacionados ao tema. Os autores dividiram ACS em duas áreas de foco - estratégia e operações - e para cada uma das áreas sugeriram aplicações diferentes. A aplicação que despertou maior interesse foi a da planejamento de demanda. Planejamento de demanda envolve não apenas a previsão de demanda, mas também o planejamento de operações e vendas. Isso quer dizer que o planejamento de demanda não só necessita de uma elevada capacidade de prever a demanda com precisão, mas também utiliza essa informação para elaboração de planos voltados ao crescimento das empresas, podendo visar o lucro, inserção, estabelecimento de marca, etc.

É importante se atentar às diferentes formas de se olhar para os dados. Para (SIVARAJAH et al., 2017), existem três tipos de métodos analíticos para *Big Data*: análises descritivas, preditivas e prescritivas. Análises descritivas são análises que olham para o passado e revelam o que já ocorreu, auxiliando no processo de informação. Análises preditivas são focadas na previsão e criação de modelos estatísticos para determinar as possibilidades para o futuro, auxiliando no processo de entendimento. Análises prescritivas são utilizadas para determinar causa e efeito entre resultados analíticos e políticas de otimização de negócios das empresas, auxiliando no processo de decisão. Particularmente, para este projeto, houve mais interesse na análise do *Big Data* através do olhar prescritivo, já que decidiu-se desenvolver um produto que não apenas olha resultados anteriores e cria projeções para o futuro, mas também auxilia na tomada de decisões voltadas ao planejamento de demanda para as empresas.

Deste modo, foram utilizadas habilidades analíticas em conjunto com conhecimento de negócios - principalmente focado na área de logística e cadeia de suprimentos. Os conhecimentos adquiridos durante a graduação foram suficientes para lidar com as partes analíticas do projeto. Quanto à parte do conhecimento específico sobre cadeias de suprimentos e logística, foram consultados especialistas na área, uma vez que a obtenção de conhecimento de domínio não é algo simples e pode levar anos para se concretizar (DUMBILL et al., 2013).

Após análise cuidadosa dos artigos e discussão com alguns especialistas na área de logística e cadeia de suprimentos (1.2), decidiu-se que o tema deste projeto seria o desenvolvimento de um produto capaz de automatizar o planejamento de demanda para empresas de *e-commerce*, aproveitando-se da grande disponibilidade de dados das empresas do setor.

Para desenvolvimento deste trabalho foram utilizados dados coletados de três empresas participantes do setor de *e-commerce*. A primeira empresa é focada no mercado de bebidas, a segunda é focada em produtos cosméticos e a terceira em moveis; as empresas, cujos nomes não foram citados, pediram para ter a identidade preservada. Ao analisar empresas diversas - que apresentam diferentes ramos, tamanhos, receitas, produtos, objetivos, etc. - espera-se chegar a um entendimento mais amplo do planejamento de demanda e consequentemente desenvolver um produto final de maior qualidade.

1.2 DISCUSSÃO COM ESPECIALISTAS

Para início de elaboração deste projeto, foram consultadas pessoas responsáveis pelo abastecimento de estoque de quatro empresas distintas assim como o CEO da empresa SELIA. As primeiras quatro empresas citadas atuam no mercado de *e-commerce* nos setores de sucos, cosméticos, móveis e alimentos, respectivamente. A última empresa citada é uma prestadora de serviços especializada em desenvolver ou aprimorar a seção de *e-commerce* de outras empresas. Durante esta subseção, serão levantados e resumidos os principais pontos discutidos nas conversas iniciais com os especialistas mencionados.

Primeiramente, com o CEO da SELIA, buscou-se entender o problema do ponto de vista do negócio e definir os principais objetivos do nosso produto. A partir dessa conversa, dividiu-se o projeto em duas principais frentes: previsão de demanda e política de reposição de estoque.

A previsão de demanda é um ponto essencial, pois é a partir dela que os outros planejamentos devem ser desenvolvidos. Uma previsão de demanda ideal deve levar em conta não só a série temporal histórica das vendas de um determinado produto, mas também fatores externos como promoções, propagandas, feriados, etc.

Além disso, é importante entender o ciclo de vida dos produtos de cada empresa, já que isso pode determinar quanto tempo um produto pode ficar em estoque. O tempo que uma cadeira pode ficar armazenada difere muito do tempo de um suco de laranja, por exemplo. O planejamento de demanda também atua na decisão da melhor maneira de se agir em casos de produtos armazenados por muito tempo. Por exemplo, talvez seja mais vantajoso para uma empresa, do ponto de vista econômico, vender produtos que estejam próximos ao vencimento a um preço mais baixo do que manter o preço e não vendê-los. Nesses casos, também é necessário estudar qual o valor do desconto que se pretende usar e como se espera que isso afete a demanda.

Ainda, foi discutido como a política de reposição de estoque pode afetar o desempenho de cada empresa. Para isso, utilizou-se um exemplo apresentado em (VOLLMANN, 2011), onde os autores explicam um fenômeno chamado de curva ABC no qual constata-se que para empresas que vendem vários produtos, 20% dos produtos representam 65% da rotatividade do caixa, 30% dos produtos representam 25% da rotatividade do caixa e o resto, 50%, dos produtos representam apenas 10% da rotatividade do caixa. Os três grupos diferentes são chamados de grupo A, B e C, respectivamente. Os autores reconhecem que os valores das porcentagens podem variar de caso a caso, mas o ponto principal é que é usual achar nas empresas um pequeno grupo de produtos representando uma grande parte das receitas. Uma boa política de reposição de estoque deve ser capaz de entender quais produtos são mais importantes para empresa e priorizar os que possuem maior impacto na receita.

Por fim, foi discutido o planejamento de vendas e operações, também através de um exemplo. Em geral, as empresas visam gerar lucro, mas nem sempre esse é o objetivo

principal. Por exemplo, existem casos em que as empresas querem aumentar sua inserção no mercado e para isso vendem produtos com uma baixa margem de lucro. Para um bom planejamento de demanda, é necessário entender se um produto com baixa margem de lucro está de acordo com a estratégia da empresa ou se está de fato prejudicando a empresa.

A discussão com o diretor comercial da empresa de móveis trouxe um ponto de vista mais prático do problema. Como ele é o principal responsável pelo planejamento de demanda da empresa e já trabalhou com isso em empresas dos mais diversos setores, foi possível entender como funciona de fato o processo e quais as suas dificuldades.

O primeiro ponto levantado foi da dificuldade de se desenvolver um produto que atendesse diferentes setores do mercado digital, principalmente no que diz respeito à validade, ciclo de vida e recorrência de compra. Além disso o *e-commerce* possui diferentes modalidades de vendas, o site próprio (1P) e o *marketplace* (3P) são as principais. A partir desse debate, optou-se por afunilar o problema visando apenas vendas 1P, pois é o mais comum e apresenta mais dados, e por explorar os diferentes casos de mercado, buscando uma solução que seja eficiente de maneira generalista.

A conversa também foi importante para entender como a previsão de demanda é feita na empresa, bem como pontuar suas particularidades - seus produtos não tem validade nem ciclo de vida definido e o tempo de reposição pode variar dependendo se é um produto nacional ou importado. No momento de produção deste trabalho, utilizava-se uma planilha no *Excel* que era preenchida manualmente e contava com diversos parâmetros de ajuste. O problema desse método era que, apesar de contar com uma análise quantitativa, muito dos parâmetros de ajuste eram baseados em análises subjetivas, que, apesar de serem feitas por profissionais, podiam levar a resultados imprecisos.

Com base na discussão, foi possível discutir sobre quais dados seriam necessários para o trabalho. Independentemente da complexidade da análise, é necessário ter o histórico de vendas de cada produto, pois essa será a base da previsão. É interessante saber o estado do estoque no tempo, para que seja possível associar uma queda nas vendas à falta de estoque, por exemplo. Além disso, dados de promoções e investimentos em campanhas de marketing digital também podem ser importantes fatores externos à série histórica que influenciam diretamente o seu comportamento, principalmente no contexto do *e-commerce*. Outros dados também listados foram características físicas dos produtos e suas categorias que, apesar de não estarem diretamente relacionados com a evolução das vendas no tempo, poderiam refinar a previsão e auxiliar na decisão de reposição de estoque.

Posteriormente, no momento da conversa com o diretor comercial da empresa de cosméticos, a ideia do trabalho já estava mais madura. Assim, foi possível apresentar o projeto em maiores detalhes para entender as necessidades do usuário final e, principalmente, confirmar se a solução a ser desenvolvida era de interesse da empresa.

O entrevistado demonstrou muito interesse no produto, já que ele já havia procu-

rado softwares de planejamento de demanda voltados para o *e-commerce* no mercado e não havia encontrado nada que satisfizesse suas necessidades. Vale observar que as funcionalidades desejadas, bem como as dificuldades enfrentadas eram semelhantes às aquelas mencionadas pelo diretor comercial da empresa de móveis, diferindo apenas nas particularidades de seus modelos de negócio.

De maneira geral, apesar de representarem empresas de características diferentes, os especialistas consultados apresentaram bastante interesse no projeto.

1.3 REVISÃO BIBLIOGRÁFICA

Para estabelecer um ponto de partida, realizou-se uma pesquisa na bibliografia para determinar como o problema foco do nosso trabalho, e problemas parecidos, vêm sendo resolvidos ao longo do tempo. Na subseção 1.3.1, apresentou-se os trabalhos escolhidos durante essa etapa e explicou-se como cada um deles foi relevante para este trabalho.

1.3.1 Estado da Arte

A busca por maneiras de melhorar a eficiência do planejamento de vendas e operações não é algo recente no mundo dos negócios. Por outro lado, a quantidade de informação disponível assim como as formas de compartilhamento dessa informação estão em constante evolução. Diante desse contexto, é importante avaliar o impacto que essas mudanças estão proporcionando.

Em (CACHON; FISHER, 2000), o autor comparou os custos de uma cadeia de suprimentos com uma política de informação tradicional, que compartilha apenas informações de vendas do produto final, e uma cadeia que também compartilha em tempo real outras informações, como o estado do estoque do produto. O estudo concluiu que o segundo modelo é capaz de trabalhar com remessas menores e tempos de reposição mais rápidos, diminuindo o custo da operação e aumentando sua velocidade. Além disso, em (AVIV, 2004) o autor explicou a importância da construção do planejamento de demanda a partir de opiniões e modelos de diferentes áreas do negócio. O autor alegou que a decisão baseada na conciliação das previsões resulta em uma maior acurácia do que cada previsão individualmente e mostrou diversas maneiras de se fazer essa conciliação. A partir dos estudos, foi possível perceber a importância do compartilhamento de informação para empresas assim como benefícios provenientes desse compartilhamento.

A seguir, discutiu-se como os dados disponíveis para as empresas vêm sendo utilizados na construção do planejamento de demanda. Durante a discussão, o foco principal foi em como as maneiras de se fazer previsões de demanda evoluíram ao longo dos anos e como elas se encontram atualmente. Os modelos de previsão de demanda atuais levam em conta não apenas dados históricos de vendas de produtos, mas também consideram fatores externos que podem variar desde dias comemorativos ou meses do ano

até promoções de produtos ou informações meteorológicas. Esses modelos de previsão de demanda que também levam em conta fatores externos são chamados de modelos híbridos.

Em (ABURTO; WEBER, 2007), os autores propuseram um modelo híbrido de previsão de demanda baseado em dois modelos distintos. O primeiro modelo, ARIMA (Auto-regressivo Integrado de Médias Móveis), segundo os autores, foi utilizado para fazer uma previsão de demanda focada na série temporal, enquanto o segundo modelo, MLP (Perceptron Multicamadas), foi utilizado para fazer uma previsão de demanda focada em fatores externos. O modelo final proposto no estudo foi um modelo aditivo entre os dois citados anteriormente. Os autores utilizaram o modelo desenvolvido para fazer a previsão de demanda de 6 dos 50 *SKUs* mais vendidos de um supermercado chileno. Por fim, o trabalho concluiu que o modelo híbrido proposto apresentou uma performance mais acurada do que os modelos ARIMA e MLP separados, sugerindo que o modelo híbrido é melhor na previsão de demanda.

Em um estudo que serviu para ilustrar um caso concreto de utilização de dados externos na elaboração de um modelo híbrido, (YANG; PAN; SONG, 2014), os autores desenvolveram e compararam modelos de previsão de demanda distintos que incorporavam os dados de tráfego na internet de organizações de marketing de viagens para determinar a demanda por hotéis em uma cidade na Carolina do Sul nos Estados Unidos. Os modelos propostos no estudo eram baseados em auto-regressivos de médias móveis (ARMAX) e limiar auto-regressivos (TAR). Durante o estudo, os autores concluíram que modelos que levavam em conta o tráfego de internet geraram previsões com erros menores em relações a outros tipos de modelos, principalmente para previsões de curto prazo, definidas como quatro a oito semanas pelos autores. Além disso, os autores sugeriram que modelos baseados no método ARMAX performavam melhor que modelos baseados no método TAR.

Ainda sobre modelos híbridos, em (ARUNRAJ; AHRENS, 2015), os autores propuseram a utilização de um modelo baseado no método de sazonalidade auto-regressivo de média móvel com fatores externos (SARIMAX) para fazer a previsão de demanda das vendas de banana de uma loja alemã. Os autores utilizaram diversos modelos - como SARIMA de múltiplas regressões lineares (SARIMA-MLR), SARIMA com regressão por quantil (SARIMA-QR), SARIMA, etc. - para elaboração de previsões de demanda e depois compararam os resultados. Além disso, os autores sugeriram um modelo base de previsão de demanda que seria capaz de prever a demanda de uma dada semana como o mesmo número de vendas da semana anterior. O modelo base foi, posteriormente utilizado para comparação entre modelos mais sofisticados. Durante o estudo, foram propostas diferentes categorias de fatores externos que podem influenciar a demanda: eventos (como dias da semana, feriados, meses), clima, sazonalidade, preço, substituição e canibalização, características dos produtos e número de visitas de clientes. No caso específico desse estudo, foram considerados apenas fatores de eventos, clima e preço. No final, os autores concluíram que todos os modelos de previsão de demanda performaram melhor que o

modelo base e que modelos que levam em conta fatores externos geram previsões melhores que os demais. Por fim, os autores concluíram que o modelo de melhor performance é o SARIMA-QR e sugeriram ele para elaboração de previsões de demanda.

Além disso, foram pesquisadas referências que levaram em conta fatores externos de promoções. Em (ALI et al., 2009), os autores estudaram o impacto de promoções na previsão de demanda de *SKUs* de um mercado varejista europeu. Ao longo do estudo, os autores sugeriram modelos de diferentes níveis de sofisticação e discutiram a dificuldade de implementação do modelo em relação à sua precisão. O modelo base do trabalho foi o de suavização exponencial que, segundo os autores, para períodos estáveis e sem promoções, era ideal, já que apresentava baixa complexidade e alta acurácia. Entretanto, na presença de promoções, o modelo de suavização exponencial não mostrava uma acurácia boa. Para resolver esse problema, os autores utilizaram técnicas de aprendizado de máquina como SVR (*Support Vector Regression*) e árvores de regressão. O uso dessas técnicas possibilitou a obtenção de resultados com erros até 24% menores em relação ao modelo base, mostrando uma vantagem significativa. Esse estudo foi importante para demonstrar a diferença de performance entre os modelos estatísticos e os modelos de aprendizado de máquina, bem como seus casos de uso.

Um outro trabalho, mais recente, que levava em conta as promoções para a realização do planejamento de demanda foi escrito por (MA; FILDES; HUANG, 2016). Nele, os autores afirmaram que não há um método aceito na literatura para criação de estratégia de promoções e previsões operacionais a nível de *SKU* que levasse em conta as informações promocionais intra e inter categorias de produtos e portanto propuseram uma solução própria. O método proposto no estudo consistia na identificação de potenciais categorias influenciadoras para cada *SKU*, construção de um espaço das potenciais variáveis a serem consideradas, escolha de variáveis com estimativa do modelo usando múltiplas regressões de Lasso e, por fim, geração de previsões para cada *SKU* utilizando os modelos desenvolvidos previamente. Os autores também testaram o método num caso específico e concluíram que a utilização do método deles poderia melhorar a previsão de demanda 12,6% acima do modelo base, com a maior contribuição sendo proveninete de informações intra categoria para cada *SKU*. Esse trabalho mostrou uma maneira de incorporar informações de promoção de cada *SKU* intra e inter categoria de produtos, visando melhorar o desempenho dos modelos de previsão de demanda.

Por fim, vale ressaltar que a previsão de demanda está tomando uma dimensão cada vez mais individualizada por usuário. Em (FENG; SHANTHIKUMAR, 2018), foi sugerida uma forma de previsão de demanda extremamente granular, de cliente para cliente. Os autores acreditavam que a previsão de demanda feita num nível individual poderia ser melhor que um planejamento de demanda agregado e sugeriram modelos matemáticos para se estimar demandas para indivíduos tanto para lojas físicas quanto para online. Segundo o estudo, a individualização da previsão de demanda poderia ajudar as empresas

a desenvolverem preços e campanhas de marketing específicas para cada cliente. No final, a demanda agregada da empresa era dada pela soma individual da demanda de cada cliente, o que seria bem interessante do ponto de vista de planejamento de vendas e operações. Vale ressaltar que os autores não aplicaram de fato a individualização da demanda em um caso específico para uma possível avaliação de resultados.

2 REQUISITOS

O objetivo deste projeto é o desenvolvimento de uma aplicação capaz de auxiliar a tomada de decisão de um usuário inserido na cadeia de suprimentos. Para entendimento das necessidades desse tipo de usuário foram realizadas conversas com especialistas retratadas em 1.2 e, a partir dessas conversas, foram estabelecidos os requisitos de projeto.

O usuário para o qual este projeto é destinado é uma pessoa ou um conjunto de pessoas especialista em logística responsável por organizar o estoque de uma empresa. A aplicação se propõe a auxiliar o usuário fornecendo sugestões de política de estoque baseadas na previsão de demanda para cada um dos itens da empresa.

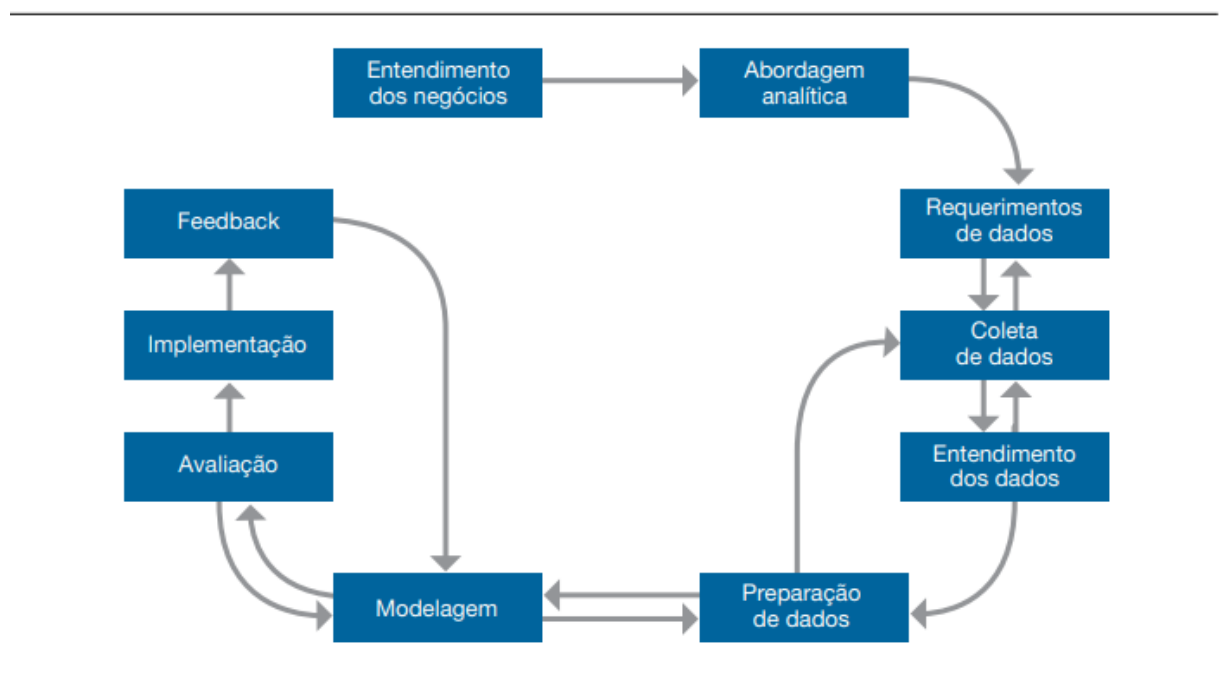
Os requisitos definidos até o momento são:

- RS0 - O sistema deve ser capaz de realizar previsões de demanda melhores que um modelo base, que será explicado posteriormente;
- RS1 - O sistema deve ser capaz de sugerir políticas de estoque que respeitem estoques de segurança de empresas;
- RS2 - O sistema deve gerar valor financeiro às empresas que forneceram os dados por meio da redução de custos ou da automatização de trabalhos.

3 METODOLOGIA

Como este trabalho é baseado na aplicação de informações extraídas através de dados, a utilização de uma metodologia voltada para ciência de dados é importante. Assim, escolhemos utilizar uma metodologia baseada na proposta em (ROLLINS, 2015). Ao longo deste capítulo, vamos discorrer brevemente sobre o conteúdo das etapas dessa metodologia e como pretendemos realizá-las. Para facilitar a visualização, um esquema da metodologia está disponível na figura 1 a seguir.

Figura 1 – Metodologia de um projeto de ciência de dados



Fonte: Rollins (2015)

A primeira etapa é o entendimento de negócios. As principais atividades desta etapa são: entender de fato o problema que se quer resolver, definir os objetivos do projeto a ser desenvolvido e estabelecer os requisitos da solução a ser apresentada. De maneira geral, é importante ter pessoas especializadas na área para a qual o projeto será realizado já que essas pessoas possuem conhecimento de domínio e experiências que podem ajudar a orientar o projeto na direção correta e garantir que a solução será relevante para eles. No caso específico de nosso projeto, como já mencionado no capítulo anterior na seção 1.2, foram consultados especialistas que ajudaram não apenas na realização das atividades desta etapa, como também foram responsáveis pelo fornecimento de conhecimento de domínio da área de logística, principalmente voltada para o planejamento de demanda.

Na segunda etapa, de abordagem analítica, define-se como o problema definido na etapa anterior será abordado analiticamente. No caso específico do nosso projeto, como

queremos prever a demanda e a partir disso definir uma estratégia de vendas que maximize algum objetivo (como o lucro, por exemplo), a abordagem analítica seria o desenvolvimento de dois modelos: um de previsão e outro de otimização.

A terceira etapa é a de requisitos dos dados. Nela, são definidos os conteúdos, formatos e representação dos dados a serem coletados, baseados nos problemas analíticos que se pretende resolver. Para nosso projeto, na parte de previsão de demanda, vamos precisar de dados de séries históricas de vendas, por exemplo. Vale ressaltar que, é necessária uma certa flexibilidade nesta etapa, pois nem todos os dados com os quais queríamos trabalhar podem ser fornecidos pelas empresas por diversos motivos como sigilosidade, por exemplo.

A quarta etapa, de coleta de dados, é a etapa na qual se define como os dados serão coletados. No caso do nosso trabalho, a coleta de dados foi feita através de solicitação direta para algumas empresas selecionadas. Note que como os dados vieram de fontes diferentes, é possível que não haja uma uniformidade na maneira como os dados foram coletados, mas isso pode ser contornado em etapas posteriores como preparação de dados, por exemplo. Além disso, a etapa de coleta de dados pode ser repetida, caso encontre-se necessário utilizar mais dados ou dados em outra formatação, por exemplo.

A quinta etapa é o entendimento dos dados. Nessa etapa, é importante explorar os dados, utilizando recursos como visualizações ou estatísticas descritivas para fazer uma avaliação preliminar dos dados, verificando a qualidade deles. Essa etapa é bem específica para os dados coletados de cada empresa e estará melhor detalhada na seção de desenvolvimento.

Na sexta etapa, durante a preparação de dados, manipulam-se todos os dados recebidos para que eles fiquem em um formato que permita a etapa de modelagem. É nesta etapa que se realizam tarefas como a limpeza dos dados, a reformatação e até a criação de novos dados que possam ser úteis nas etapas subsequentes. Novamente, como essa etapa é muito específica para cada conjunto de dados, ela será melhor detalhada no desenvolvimento.

A sétima etapa é a etapa de modelagem. É nesta etapa em que os modelos utilizados para resolver os problemas descrito na segunda etapa são desenvolvidos. Para este projeto, por exemplo, é na modelagem que os modelos de previsão de demanda e otimização de um objetivo comercial serão desenvolvidos. Vale ressaltar que essa é uma etapa iterativa em que possivelmente diversos modelos são desenvolvidos para melhor atender aos objetivos do trabalho como um todo.

A oitava etapa é a de avaliação, na qual se avalia o modelo desenvolvido na etapa anterior e se verifica se o modelo é satisfatório ou não. Existem várias técnicas para se avaliar um modelo, como elaboração de medidas de diagnóstico, visualização de gráficos e tabelas e até separação dos dados em conjuntos de treinamento e teste para verificação de desempenho do modelo em dados conhecidos. Caso um modelo seja aprovado, passa-se

para a próxima etapa, caso contrário, repete-se a etapa de modelagem e avalia-se o modelo novamente, até se chegar num modelo satisfatório.

A nona etapa, de implementação, consiste na implementação do modelo desenvolvido na empresa ou em um ambiente de teste comparável. Existem diversos níveis de implementação que variam desde a geração de um simples relatório com recomendações até a integração total do modelo no fluxo operacional de uma empresa. Para o nosso projeto, inicialmente pretende-se apenas focar em maneiras mais simples de integração, já que a integração completa de um modelo desenvolvido neste trabalho envolveria muito mais do que questões acadêmicas.

Por fim, a última etapa é a etapa de feedback. Nela, são coletados resultados relacionados à performance do modelo desenvolvido para se avaliar o impacto e desempenho do trabalho. Para este projeto, especificamente, a etapa de feedback será mais focada na avaliação das empresas sobre o produto final desenvolvido.

4 TEORIA

4.1 PREVISÃO DE DEMANDA

Previsão de demanda pode ser definida como a estimativa de vendas futuras com base em informações do presente e do passado. Uma boa previsão é fundamental para o planejamento das empresas, pois pode reduzir diversos custos de armazenamento e transporte e aumentar as margens de venda de determinados produtos ou campanhas.

Para isso, utiliza-se de diferentes tipos de métodos. Os qualitativos, em geral, se baseiam em julgamentos subjetivos e são recomendadas principalmente para previsões de longo prazo, então, durante o trabalho, não serão levados em consideração. Em contrapartida, os quantitativos são construídos com bases em técnicas e algoritmos que podem levar em consideração tanto os dados históricos quanto os dados externos com possíveis influências no volume de vendas.

Os métodos de previsão podem ser simples quanto uma média simples e complexos como uma rede neural. Por isso, mais importante do que entender toda a modelagem matemática por trás de cada um deles, é entender o horizonte de tempo e a dinâmica de mercado na qual cada modelo performa melhor. Por exemplo, para o desenvolvimento desse projeto, o objetivo da previsão é planejar as reposições de estoque dos produtos para empresas de *e-commerce*, então deve-se ter em mente que o mercado é muito dinâmico, devido a presença de promoções, lançamentos de marcas e imprevisibilidade dos clientes e o horizonte temporal é o curto prazo. A seguir, estão apresentados os algoritmos utilizados no trabalho (HYNDMAN; ATHANASOPOULOS, 2018).

4.1.1 Suavização Exponencial

A suavização exponencial é uma técnica simples de previsão a curto prazo que leva em consideração apenas o comportamento histórico das vendas. Segundo (ALI et al., 2009), esse modelo dificilmente consegue ser superado para períodos sem promoções. A suavização exponencial pode ser simples, dupla ou tripla, dependendo da complexidade necessária para a modelagem da série histórica.

4.1.1.1 Suavização Exponencial Simples

Consiste em atribuir um fator α entre 0 e 1 como peso para o período atual seguindo a fórmula

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

onde

t = período de tempo atual

α = constante da ponderada exponencial

A_t = demanda no período t

F_t = previsão para o período t

Deste modo, pode-se escolher o α apropriado para a dinâmica do negócio. Enquanto que em períodos mais estáveis, utiliza-se um fator baixo (menor que 0,3), em períodos de crescimento rápido ou de promoção utiliza-se um fator alto.

4.1.1.2 Suavização Exponencial Dupla

Para adicionar o ajuste de tendência, pode-se adicionar uma componente T . Assim, podemos calcular a previsão seguindo as equações

$$S_{t+1} = \alpha A_t + (1 - \alpha)(S_t + T_t) \quad (2)$$

$$T_{t+1} = \beta(S_{t+1} - S_t) + (1 - \beta)T_t \quad (3)$$

$$F_{t+1} = S_{t+1} + T_{t+1} \quad (4)$$

onde

F_{t+1} = previsão com tendência corrigida para o período $t + 1$

S_t = previsão inicial para o período t

T_t = tendência para o período t

β = constante ponderada da tendência

4.1.1.3 Suavização Exponencial Tripla

Em grande parte dos históricos de vendas, existe um claro padrão sazonal que se repete em períodos de 12 meses. Para incorporar esse padrão no modelo, calcula-se um índice de sazonalidade I que se repete a cada L períodos de tempo. As equações desse modelo estão listadas abaixo:

$$S_{t+1} = \alpha(A_t/I_{t-L}) + (1 - \alpha)(S_t + T_t) \quad (5)$$

$$T_{t+1} = \beta(S_{t+1} - S_t) + (1 - \beta)T_t \quad (6)$$

$$I_t = \gamma(A_t/S_t) + (1 - \gamma)I_{t-L} \quad (7)$$

$$F_{t+1} = (S_{t+1} + T_{t+1})I_{t-L+1} \quad (8)$$

onde

F_{t+1} = tendência e previsão corrigida sazonalmente para o período $t + 1$

γ = constante de ponderação do índice sazonal

I_t = índice sazonal para o período t

L = o tempo de uma estação completa

Para utilizar o modelo de suavização exponencial tripla, é necessário que o padrão de variação sazonal seja claro e bem definido e que haja conhecimento dos motivos das variações nos determinados períodos.

4.1.2 Modelo SARIMAX

O modelo auto-regressivo integrado de médias móveis sazonal com variáveis externas (SARIMAX) é um modelo de previsão que leva em consideração dados históricos com componentes de tendência e sazonalidade e dados externos. Como esse modelo é uma junção de diversos modelos mais simples, cada um deles será explicado individualmente a seguir.

4.1.2.1 Modelo Auto-regressivo (AR)

O modelo auto-regressivo consiste em fazer uma regressão linear com os valores passados da série temporal. Assim, em um $AR(p)$ (AR de ordem p), atribui-se pesos ϕ_i para cada uma das últimas p observações:

$$X_t = c + \sum_{i=1}^p \phi_i X_{t-i} + \varepsilon_t \quad (9)$$

onde

X_t = demanda no período t

c = constante da regressão linear

ϕ_i = parâmetros da regressão linear da demanda

ε_t = erro no período t

4.1.2.2 Modelo de Médias Móveis (MA)

O modelo de médias móveis consiste em fazer uma regressão linear com os erros passados da série temporal. Assim, em um $MA(q)$ (MA de ordem q), atribui-se pesos θ_i para cada uma das últimas q observações:

$$X_t = \mu + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (10)$$

onde

μ = média de demanda da série

θ_i = parâmetros da regressão linear do erro

4.1.2.3 Modelo Auto-regressivo de Médias Móveis (ARMA)

O ARMA consiste na junção dos dois modelos anteriores. Um ARMA(p,q) pode ser equacionado da seguinte maneira:

$$X_t = c + \sum_{i=1}^p \varphi_i X_{t-i} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (11)$$

4.1.2.4 Modelo Auto-regressivo Integrado de Médias Móveis (ARIMA)

O modelo ARIMA leva em conta a tendência da demanda, aplicando o ARMA na série temporal diferenciada d vezes. Para encontrar a série diferenciada, basta obter

$$X'_t = X_t - X_{t-1} \quad (12)$$

Assim, um ARIMA(p,d,q) segue a equação

$$X_t^{(d)} = c + \sum_{i=1}^p \varphi_i X_{t-i}^{(d)} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \varepsilon_t \quad (13)$$

onde

$X_t^{(d)}$ = demanda no período t diferenciada d vezes

4.1.2.5 ARIMA Sazonal (SARIMA)

O modelo SARIMA adiciona uma componente de sazonalidade ao ARIMA. Para descrever a sazonalidade, utilizamos o SARIMA(p,d,q)(P,D,Q) $_m$ que segue a equação

$$X_t^{(d)} = c + \sum_{i=1}^p \varphi_i X_{t-i}^{(d)} + \sum_{i=1}^P \Phi_i X_{t-m.i}^{(D)} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \sum_{i=1}^Q \Theta_i \varepsilon_{t-m.i} + \varepsilon_t \quad (14)$$

onde

Φ_i = parâmetros da regressão linear da componente sazonal da demanda

Θ_i = parâmetros da regressão linear da componente sazonal do erro

m = duração de um ciclo de sazonalidade

4.1.2.6 SARIMA com variáveis externas (SARIMAX)

Por fim, o modelo SARIMAX utiliza de um vetor de variáveis externas para a previsão da série temporal.

$$X_t^{(d)} = c + \sum_{i=0}^k \beta_i Y_{i,t} + \sum_{i=1}^p \varphi_i X_{t-i}^{(d)} + \sum_{i=1}^P \Phi_i X_{t-m.i}^{(D)} + \sum_{i=1}^q \theta_i \varepsilon_{t-i} + \sum_{i=1}^Q \Theta_i \varepsilon_{t-m.i} + \varepsilon_t \quad (15)$$

onde

$Y_{i,t}$ = valor da variável externa i correspondentes à demanda X_t

β = parâmetros da regressão linear das variáveis externas

4.2 POLÍTICA DE REPOSIÇÃO

Uma política de reposição pode ser definida como as diretrizes seguidas por uma empresa em relação ao estoque. Essas diretrizes podem variar desde o tamanho do pedido de novos itens para repor o estoque até mudança de preços e investimentos em marketing, (ARROW; HARRIS; MARSCHAK, 1951). Ao longo desta seção, irá se explicar brevemente a teoria necessária para se entender as características de políticas de estoque. Para isso, utilizará-se como base o material disponível em (BALLOU, 2004).

Primeiramente, é necessário explicar a importância de manter um certo nível de estoque. Ter um produto em estoque implica na disponibilidade imediata desse produto para uma venda. Por exemplo, caso um produto, que demore dois meses para ser fabricado, esteja estocado, é possível vender ele num prazo de tempo muito menor do que o tempo de fabricação. Dessa maneira, ter produtos estocados pode melhorar o serviço ao consumidor final; por outro lado, não ter um produto estocado pode acarretar na perda de uma venda.

Ter estoques pode também ser financeiramente mais interessante do que não ter, pois, dependendo dos níveis de estoque, é possível reduzir os custos totais operacionais mesmo considerando-se os custos de manutenção do estoque. Geralmente, o custo por unidade para produção de um bem qualquer diminui com o aumento da quantidade produzida e, com isso, pode ser vantajoso comprar uma quantidade maior do que a estritamente necessária e estocá-la. Além disso, estoques garantem um certo nível de segurança contra incertezas intrínsecas e extrínsecas ao canal de suprimentos. Por exemplo, atrasos no prazo de entrega ou greves trabalhistas podem acarretar na deterioração das operações de uma empresa, mas os efeitos negativos podem ser mitigados nas vendas - e consequentemente na receita - se houver um estoque planejado para tais situações.

Por outro lado, manter níveis de estoque muito elevados pode ser prejudicial, pois além de necessitar de uma quantidade maior de capital investido, também requerem um maior desembolso relacionado aos custos de manutenção. Assim, é necessário achar uma maneira de se definir a quantidade ideal de estoque que se deve ter a cada instante; para isso serve a política de estoque.

Existem duas filosofias básicas para gerenciamento de estoque que giram em torno dos conceitos de *puxar* e *empurrar*. Para a filosofia de *puxar*, define-se a política de estoque através do ponto de vista dos centros de distribuição e não dos fornecedores ou fábricas. A demanda e quantidade de produtos a serem pedidos são calculadas para cada centro de distribuição e assume-se que os fornecedores terão capacidade de suprir as necessidades de todos. A filosofia de *empurrar* pode ser ilustrada com um exemplo no qual uma empresa precisa fazer pedidos de um produto cujo lote mínimo definido pelo fornecedor excede a

soma das necessidades dos centros de distribuição da empresa. Nesse caso, assumindo que a empresa decida comprar o produto, *empurra-se* a quantidade excedente de produtos entre os centros de distribuição da empresa adotando-se algum tipo de critério como ponderação das demandas dos centros de distribuição, por exemplo. A primeira filosofia garante um maior foco nos centros de distribuição e, por isso, serão apresentados modelos teóricos baseados nela, mas para desenvolvimento deste trabalho, também irá se considerar aspectos da outra filosofia, principalmente para lidar com pedidos mínimos.

4.2.1 Método do ponto de pedido com demanda constante

O método do ponto de pedido se baseia em acompanhar os níveis de estoque de cada um dos itens e fazer o pedido de uma quantidade Q fixa de um item assim que o nível de estoque desse item cair abaixo de um certo valor ROP .

Inicialmente, para se definir a quantidade ideal de itens para se pedir em uma encomenda, pode-se equacionar os custos totais relacionados ao estoque TC como na equação 16, que soma os custos relacionados à aquisição com os custos relacionados à manutenção de um estoque. Note que nesse caso não há custos relacionados à falta de estoque, pois, se a demanda é constante, é possível adotar uma política em que ela sempre é suprida e portanto não há falta de produtos.

$$TC = \frac{D}{Q}S + \frac{ICQ}{2} \quad (16)$$

onde

Q = tamanho do pedido para reposição do estoque

D = demanda dos itens a uma taxa constante

S = custo de realização de um pedido

C = valor do item

I = custo da manutenção como percentagem do valor do item

Note que na equação 16 dividiu-se a segunda parcela da soma por 2, pois $Q/2$ representa a quantidade média de itens em estoque. É possível achar o valor de Q que minimiza 16 através da derivada da função em relação a Q .

$$Q = \sqrt{\frac{2DS}{IC}} \quad (17)$$

Como sabe-se a quantidade a ser pedida e a demanda dos itens, é possível calcular o intervalo ótimo entre pedidos T .

$$T = \frac{Q}{D} \quad (18)$$

Por fim, pode-se calcular o ponto de reposição ROP do estoque a partir do qual deve-se fazer uma nova encomenda de Q produtos.

$$ROP = d * LT \quad (19)$$

onde

d = taxa de demanda, em itens por unidades de tempo

LT = prazo médio de entrega, em unidades de tempo

4.2.2 Método do ponto de pedido com demanda incerta

Uma variação do método apresentado anteriormente pode ser feita quando consideramos que a demanda é incerta ao invés de constante. Esse caso é mais interessante, pois, além de se enquadrar mais com demandas reais e depender de previsões de demanda não constantes, também consegue lidar com erros de previsão. Como consequência da incerteza na demanda, esse método conta com um estoque de segurança.

A quantidade Q é calculada da mesma maneira que na equação 17. A quantidade ROP , por outro lado, é calculada através de uma nova expressão que leva em conta o erro de previsão de demanda.

$$ROP = d * LT + z(s'_d) \quad (20)$$

O valor de z representa o número de desvios padrões da média de uma distribuição normal para uma probabilidade associada P , que representa a probabilidade de um produto estar em estoque durante o prazo de entrega. O valor de z pode ser retirado da tabela de distribuição normal. O valor s'_d é o desvio padrão da previsão levando em conta o prazo de entrega LT , de forma que $s'_d = s_d\sqrt{LT}$, onde s_d é o desvio padrão da previsão de demanda.

Para este método, o nível médio de estoque AIL pode ser calculado como o estoque regular somado com o estoque de segurança.

$$AIL = \frac{Q}{2} + z(s'_d) \quad (21)$$

Além disso, pode-se calcular o custo total relacionados ao estoque como a soma dos custos de aquisição, manutenção (do estoque regular e do de segurança) e de falta de estoque. Note que o custo de falta de estoque foi introduzido devido à natureza incerta da demanda.

$$TC = \frac{D}{Q}S + IC\frac{Q}{2} + ICzs'_d + \frac{D}{Q}ks'_dE(z) \quad (22)$$

onde

k = custo unitário da falta de estoque

$E_{(z)}$ = função perda unitária normal; pode-se encontrar essa função tabelada na literatura. A definição dela está apresentada a seguir

$$E(z) = \phi(z) - z(1 - \Phi(z)) \quad (23)$$

onde

ϕ = função densidade de probabilidade normal de z

Φ = função de distribuição acumulada normal de z

Por fim, é possível definir o nível de serviço ao cliente SL como a probabilidade de um cliente ser atendido nesse modelo através da expressão a seguir.

$$SL = 1 - \frac{s'_d(E(z))}{Q} \quad (24)$$

4.2.3 Método prático: sistema Mín-Max


Baseado nos modelos explicados anteriormente, foi desenvolvido um sistema prático de política de estoque amplamente adotado na indústria chamado mín-max. O sistema recebe esse nome, pois calcula dois valores de estoque, um máximo e um mínimo. O valor mínimo representa o valor para abaixo do qual se deve fazer um pedido de reposição. O valor máximo representa o valor que o nível de estoque não deve exceder.

Em (BALLOU, 2004), há a descrição de como implementar o sistema. Primeiramente, é necessário determinar a natureza da demanda. Em seguida, deve-se calcular a quantidade Q do pedido da maneira que for apropriada. Calcula-se então o nível mínimo ROP como sugerido na equação 20, mas também levando em consideração um *déficit previsto* que é a quantidade que o estoque em mãos tende a cair antes da emissão de um pedido. Pode-se aproximar o *déficit previsto* como metade da diferença entre as quantidades final e inicial entre atualizações da quantidade de estoque em mãos. Então, define-se o nível máximo de estoque como a soma da quantidade de pedido com a quantidade mínima subtraída do *déficit previsto*. Por fim, executa-se o sistema de controle mín-máx, emitindo pedidos de reposição toda vez que o nível de estoque cair abaixo da quantidade ROP , pedindo quantidades iguais à diferença entre o nível máximo e o estoque em mãos.

4.2.4 Método de revisão periódica para um único item

Os métodos vistos até agora requerem atenção a todo momento para os níveis de estoque. Entretanto, existe um método em que as revisões e pedidos de estoque são feitos periodicamente ao invés de constantemente. Isso, além de disponibilizar mais tempo para os funcionários da empresa, permite um melhor preparo para realização de pedidos, em troca de níveis de estoque ligeiramente mais elevados. Esse método se mostra muito bom para organização de encomendas de estoques de múltiplos itens ao mesmo tempo que é uma situação mais próxima à realidade. Inicialmente, entretanto, irá se apresentar o método para apenas um item. O funcionamento do método está ilustrado na figura 2.

Figura 2 – Método de revisão periódica para um único item



Fonte: Ballou (2004)

Primeiramente, calcula-se uma aproximação aceitável para o intervalo de tempo entre revisões e pedidos. utiliza-se a equação 17 para calcular um valor inicial para Q e, a partir desse valor, calcula-se o valor do intervalo T como na equação 18. A partir de T , é possível calcular o nível máximo de estoque M , que é utilizado para o cálculo da quantidade de produtos que deve ser pedida no momento de revisão de estoque.

$$M = d(T + LT) + z(s'_d) \quad (25)$$

$$s'_d = s_d \sqrt{T + LT} \quad (26)$$

Para determinar a quantidade de estoque a ser pedida, calcula-se a diferença entre M e o valor de estoque no momento de revisão. O nível médio de estoque para esse modelo é dada por AIL .

$$AIL = \frac{Td}{2} + z(s'_d) \quad (27)$$

O custo de estoque e o nível de serviço podem ser calculados como nas equações 22 e 24, respectivamente.

4.2.5 Método de revisão periódica para um conjunto de itens

Na prática, realizar pedidos para cada um dos itens de uma empresa torna-se inviável, principalmente se considerarmos que algumas empresas trabalham com centenas

de produtos diferentes. Por isso, é necessário desenvolver um modelo para determinar como devem ser realizados pedidos de itens em conjunto. Nesse tipo de modelo, produtos distintos no mesmo conjunto possuem o mesmo tempo de revisão e são entregues ao mesmo tempo a partir do mesmo lugar, portanto, faz sentido tentar criar esses agrupamentos cautelosamente.

Primeiramente, calcula-se o prazo de revisão de estoque T para o conjunto de produtos definido.

$$T = \sqrt{\frac{2(O + \sum_i S_i)}{I \sum_i C_i D_i}} \quad (28)$$

A partir do prazo de revisão, calcula-se o valor máximo M_i para cada produto e, a partir dele, determina-se a quantidade de produto que será necessária encomendar baseado na mesma lógica apresentada no método anterior.

$$M_i = d_i(T + LT) + z_i(s'_d)_i \quad (29)$$

Por fim, é possível calcular os custos de estoque associados ao conjunto de produtos TC a partir da expressão abaixo.

$$TC = \frac{O + \sum_i S_i}{T} + \frac{TI \sum_i C_i D_i}{2} + I \sum_i C_i z_i(s'_d)_i + \frac{1}{T} \sum_i k_i(s'_d)_i (E_{(z)})_i \quad (30)$$

Note que O representa os custos de aquisição em conjunto. Além disso, os níveis de serviço para cada produto podem ser calculados como na equação 24, fazendo a manipulação da equação 18 para $Q = T * d$.

4.2.6 Discussão sobre os métodos

A partir da explicação dos métodos de política de estoque, espera-se ter se desenvolvido uma base teórica sólida para aprofundamento durante o desenvolvimento do trabalho. Vale ressaltar, entretanto, que os modelos apresentados durante esta subseção são teóricos e, para aplicação em situações reais, talvez precisem de algumas mudanças. Por exemplo, algumas empresas precisam comprar um lote mínimo de um produto para repor seu estoque, fazendo com que a compra nas quantidades sugeridas pelos modelos teóricos nem sempre seja possível. Além disso, algumas empresas podem ter preferências específicas em relação ao seu estoque de segurança, fazendo com que os estoques de segurança sugeridos teoricamente nem sempre sejam adotados.

5 DESENVOLVIMENTO DO PROJETO

O projeto consiste na modelagem da demanda e de diferentes políticas de reposição de estoque, seguindo parâmetros especificados pelo usuário. Utilizando dados de vendas, produtos e estoques e respeitando parâmetros definidos pelo usuário (estoque de segurança, tamanho mínimo de reposição e tempo de reposição), o objetivo é gerar valor através de previsões de demanda acuradas e políticas de estoque eficientes.

Para seguir com o desenvolvimento do projeto, foi utilizada a metodologia exposta no capítulo 3. Vale ressaltar que as duas primeiras etapas da metodologia, de entendimento de negócio e abordagem analítica, já foram discutidas anteriormente.

5.1 REQUERIMENTOS DOS DADOS

Os dados coletados deveriam permitir que o projeto cumprisse os objetivos de fornecer ao usuário tanto previsões de vendas quanto sugestões de ações para reposição de estoque. No mínimo, seria necessário coletar informações sobre a série histórica de vendas da empresa e a posição de seu estoque atual. Como discutido no estado da arte, também seria possível utilizar informações adicionais para complementar o modelo.

A partir das discussões com os especialistas (seção 1.2) e da revisão bibliográfica (seção 1.3), foi decidido que os dados solicitados para as empresas seriam:

- série histórica de vendas
- informações sobre os produtos
- posição atual do estoque
- série histórica de movimentações de estoque
- informações sobre promoções passadas e futuras

5.2 COLETA DOS DADOS

Os dados utilizados no trabalho pertencem à empresas privadas e, por isso, não foram facilmente obtidos. Foi necessário apresentar o projeto, bem como seu valor, para ganhar a confiança e o apoio das empresas. Vale mencionar que foi necessário assinar um contrato de confidencialidade, para evitar a identificação da empresa no trabalho.

As empresas então enviaram os dados estruturados de vendas, movimentações de estoque e produtos em formato *.csv* e dados não estruturados de promoções em formato *.xlsx*.


5.3 ENTENDIMENTO DOS DADOS

A partir desta seção, para ilustrar o desenvolvimento, se utilizou dados de apenas uma das três empresas estudadas no projeto no intuito de evitar repetições. Os resultados finais, entretanto, foram apresentados para cada uma das empresas.

Com os arquivos em mãos, o primeiro passo foi explorar os dados das empresas para buscar entender seu conteúdo. Utilizando códigos em *Python* e o *software Microsoft Power BI*, foi possível assegurar que todas as linhas estavam completas, verificar o tipo de informação de cada campo e o tamanho do conjunto de dados, bem como construir visualizações.

Na figura 3, pode-se visualizar o comportamento histórico dos 5 produtos com maior número de unidades vendidas (à esquerda) e dos 5 produtos com maior faturamento em reais (à direita).

Figura 3 – Histórico de vendas de produtos notáveis¹



A partir dos gráficos, pôde-se perceber uma tendência de crescimento, principalmente se tratando de unidades vendidas. Outra informação importante de se notar foi a de que, em geral, os produtos mais vendidos não foram os mesmos dos produtos que trouxeram maior faturamento.

Buscando uma maior consistência dos dados, decidiu-se agrupar os *SKU's* por sabor, diminuindo assim a granularidade e aumentando número de observações do conjunto a ser analisado, como apresentado na figura 4. O gráfico mostrou que os três sabores de maior faturamento ditam o comportamento das vendas da empresa e evoluem de maneira parecida.

Para entender a distribuição do faturamento por *SKU* das empresas e saber como priorizar os *SKU's* nas políticas de estoque, traçou-se a curva ABC, como apresentada na figura 5.

Por fim, utilizou-se o gráfico na figura 6 para ver o comportamento a movimentação do estoque nas empresas atualmente. Pôde-se perceber que a entrada de itens em estoque

Figura 4 – Análise por sabor: distribuição do faturamento (à esquerda) e histórico de vendas (à direita)


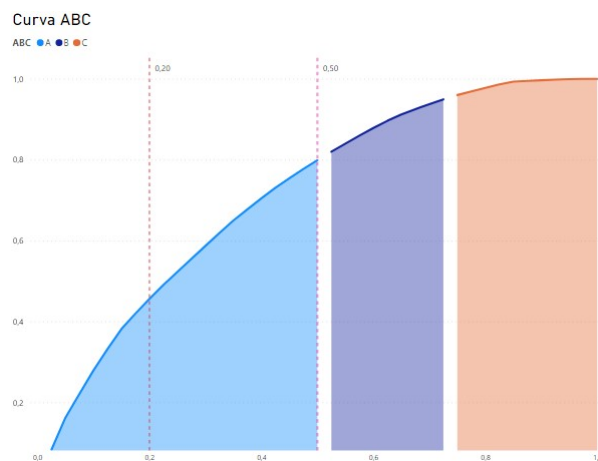
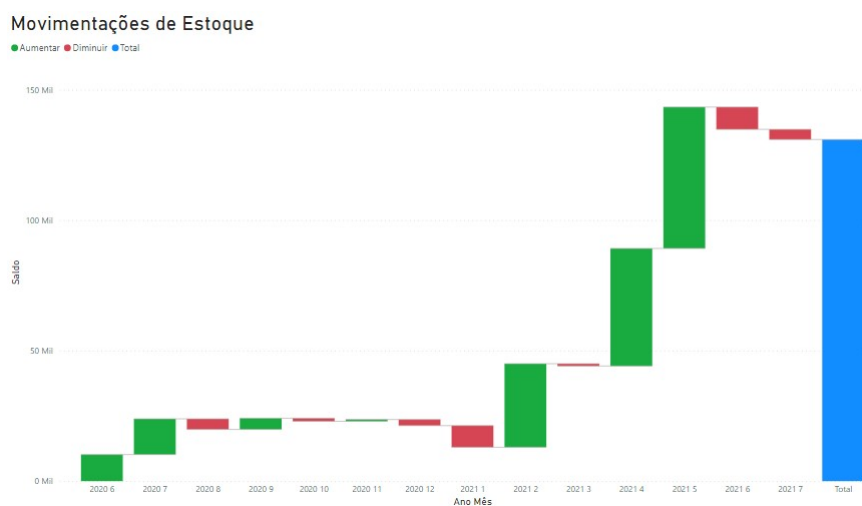


Figura 5 – Curva ABC



nos meses mais recentes foi muito maior do que a saída, assim mostrando um grande potencial de impacto do projeto a ser desenvolvido.

Figura 6 – Movimentações de estoque



5.4 PREPARAÇÃO DOS DADOS

Os dados fornecidos pelas empresas se mostraram de alta qualidade, devido a ausência de lacunas e formato estruturado (.csv). Deste modo, a etapa de preparação dos dados consistiu basicamente em decidir o agrupamento das datas a ser utilizado. Os dados de vendas mais antigos eram do final de 2019, então agrupar mensalmente resultaria em um conjunto de dados muito pequeno. Os dados diários se mostraram muito ruidosos, então optou-se pelos dados na frequência semanal. Uma vantagem desse agrupamento é que o tempo de reposição das empresas era em múltiplos semanais, assim, a granularidade dos dados da previsão conversaria facilmente com o modelo de reposição de estoque.

5.5 MODELAGEM

Durante a etapa de modelagem foi necessário desenvolver modelos para previsão de demanda e para política de estoque. O *software* utilizado para esse desenvolvimento foi o *Python* (ROSSUM; DRAKE, 2009). Para ilustração de como foi feita a modelagem, foram utilizados dados de vendas totais de uma das empresas estudadas agrupados por semana.

5.5.1 Previsão de Demanda

A modelagem de previsão de demanda foi dividida em 4 etapas: definição do modelo base, definição da métrica do erro, tratamento de *outliers* e escolha dos parâmetros, explicadas a seguir.

– Modelo Base:

Para efeito de comparação dos resultados, foi necessário estabelecer um modelo base. Neste modelo, o cálculo da previsão de demanda para um instante t , $P(t)$, é feito através da média aritmética das vendas nas k observações anteriores à t .

$$P(t) = \frac{1}{k} \sum_{i=1}^k V(t-i) \quad (31)$$

– Definição da métrica de erro:

Para qualificar as previsões e quantificar seus respectivos erros, optou-se por utilizar um valor percentual, pois como as séries não são necessariamente estacionárias, a modelagem por erros absolutos priorizaria o erro nas épocas com maiores volumes de vendas. Além disso, seria possível comparar a performance dos modelos entre as diferentes empresas. Deste modo, foi utilizada a métrica de erro médio absoluto percentual da sigla em inglês *MAPE*, definida na equação 32.

¹Vale notar que as lacunas nos gráficos se devem a meses sem venda e não a dados faltantes.

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{|V_{ri} - V_{pi}|}{V_{ri}} \quad (32)$$

onde

V_{pi} = Valor da i-ésima previsão

V_{ri} = Valor real referente à i-ésima previsão

– Tratamento de *outliers*:

Durante a modelagem inicial, percebeu-se que a presença dos *outliers* comprometia o processo de escolha de parâmetros. Como haviam valores muito destoantes dentro das séries temporais, o erro percentual referente a esses pontos no tempo ficava uma ordem de grandeza maior do que os outros erros. Sendo assim, o *MAPE* dos modelos dependia muito da performance nesses pontos e não da performance na série como um todo.

Para lidar com esse problema, decidiu-se limitar os valores da série temporal utilizando os valores de média e desvio padrão das 10 últimas observações:

$$lim_{sup,inf} = \mu_{10} \pm 2 * \sigma_{10} \quad (33)$$


onde

$lim_{sup,inf}$ = Limites superior e inferior

μ_{10} = Média das últimas 10 observações

σ_{10} = Desvio padrão das últimas 10 observações

Figura 7 – Detecção de *outliers*



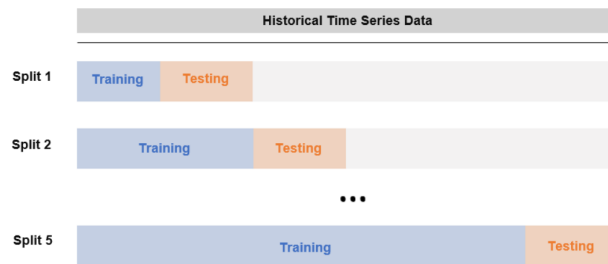
– *Escolha dos parâmetros:*

Além do modelo base, foram explorados os dois algoritmos de previsão de demanda apresentados na seção 4.1 com auxílio da biblioteca *statsmodels* (SEABOLD; PERKTOLD, 2010). A escolha dos parâmetros de cada um dos modelos foi feita com o intuito minimizar o valor do *MAPE* em uma janela de previsão de 2 semanas, já que esse é aproximadamente o tempo que as empresas levariam para repor um produto.

Para encontrar os melhores parâmetros, foi necessário se atentar para não criar modelos enviesados, ou seja, que funcionam bem para os dados disponíveis, mas não para dados novos. Pensando nisso, foi utilizado o método *walking forward validation* que consiste em treinar o modelo com uma parte da série e gerar a previsão para a janela desejada. Esse processo foi aplicado para 10 passos para cada conjunto de parâmetros e a média do *MAPE* dos testes foi considerada para a comparação.

A figura 8 ilustra o processo de treino dos modelos.

Figura 8 – *Walk Forward Validation*



Fonte: Vien et al. (2021)

Para cada algoritmo, testou-se diversas possíveis combinações de parâmetros para encontrar o menor erro, se atentando para perceber o comportamento do erro em função dos parâmetros para evitar encontrar mínimos locais. As figuras 9a e 9b ilustram esse comportamento.

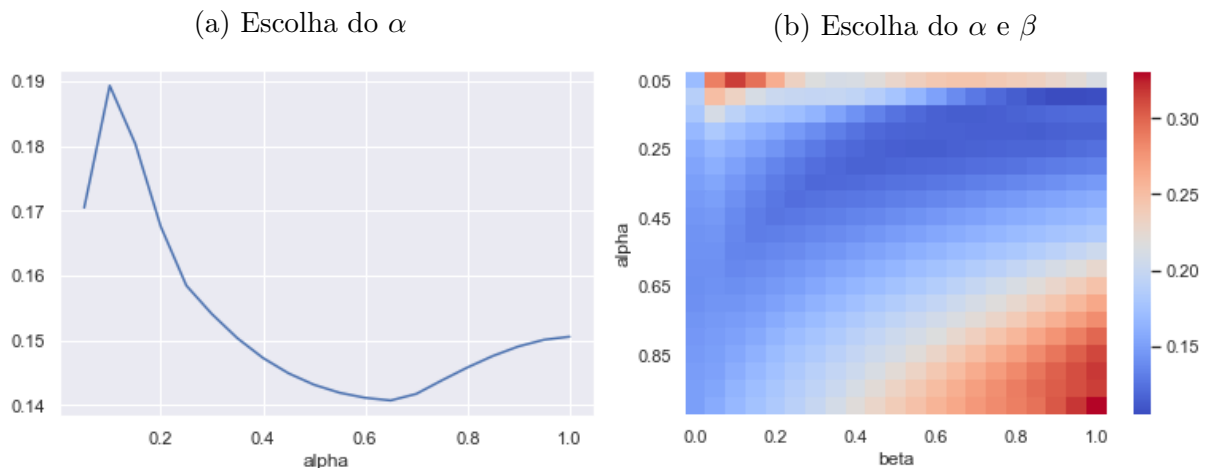


Figura 9 – Escolhas dos parâmetros para suavização exponencial simples e dupla

Os modelos utilizados, assim como seus respectivos valores de *MAPE* podem ser verificados na tabela 2.

Tabela 2 – Resultados *Walk Forward Validation* para a Empresa 1

Modelo	Parâmetros	MAPE (%)
Modelo Base	$k = 1$	18,0
Suavização Exponencial Simples	$\alpha = 0,65$	14,1
Suavização Exponencial Dupla	$\alpha = 0,1, \beta = 0,95$	10,5
ARIMA	$(p,d,q) = (3,2,0)$	11,8

A partir da tabela 2, verificou-se que os modelos apresentados na seção 4.1 performaram melhor do que o modelo base, para as vendas agregadas. Vale mencionar que as variações dos modelos que envolviam sazonalidade não foram utilizadas, pois as empresas apresentavam menos do que 2 anos completos de dados, portanto a utilização de componentes sazonais seria conceitualmente incorreta.

A tabela 3 contém os resultados dos testes dos modelos para dados não utilizados na escolha dos parâmetros.

Tabela 3 – Testes dos modelos para a Empresa 1

Modelo	Parâmetros	MAPE (%)
Modelo Base	$k = 1$	13,0
Suavização Exponencial Simples	$\alpha = 0,65$	11,1
Suavização Exponencial Dupla	$\alpha = 0,1, \beta = 0,95$	8,5
ARIMA	$(p,d,q) = (3,2,0)$	15,6

Como o objetivo final do trabalho é prever as vendas a nível de *SKU*, para a obtenção dos resultados, o processo explicado acima foi repetido para cada um dos produtos pertencentes à curva A de cada empresa. Para os produtos curva B e C, utilizou-se a média simples das últimas 3 semanas para prever a demanda da próxima semana.

5.5.2 Política de Reposição

Para a política de reposição de estoque, foram desenvolvidos dois modelos distintos, um baseado em revisões periódicas e outro baseado em acompanhamentos constantes dos níveis de estoque. Para poder testar e comparar os modelos desenvolvidos com a movimentação real de estoque, desenvolveu-se uma simulação de como seriam os níveis de estoque, caso os modelos tivessem sido aplicados. Como os modelos de reposição de estoque dependem da previsão da demanda, foi necessário escolher qual modelo de previsão seria utilizado. Como discutido ao longo deste trabalho, modelos de previsão mais sofisticados podem funcionar melhor para números maiores de observações, mas como as simulações dos modelos de política de reposição foram feitas dinamicamente desde a primeira observação,

optou-se por usar o modelo base de previsão de demanda, com o parâmetro k escolhido de acordo com o explicado na subseção anterior. Além disso, nas simulações, se houvesse uma demanda por produtos maior do que o estoque em mãos, a diferença foi contabilizada como venda perdida, mesmo se a empresa conseguisse suprir a demanda numa observação posterior após a reposição do estoque.

Para que não houvesse perda de vendas nas observações iniciais das simulações, assumiu-se que o estoque inicial era suficiente para suprir a demanda das quatro primeiras observações. Assim, evitou-se iniciar as simulações com perdas de vendas garantidas.


Inicialmente, para desenvolvimento dos modelos, as vendas da Empresa 1 foram agrupadas como se representassem apenas um produto. Posteriormente, os modelos foram aplicados para a empresa a nível de *SKU* e também para as outras empresas. Os resultados podem ser verificados no capítulo 6 de resultados.

5.5.2.1 Revisão Periódica

No modelo de revisão periódica desenvolvido, baseado no que foi apresentado na seção de teoria 4, utilizou-se a previsão de demanda, o estoque de segurança, o prazo de entrega e o intervalo entre solicitações de reposição como parâmetros para simular a movimentação de estoque da empresa.

Para a simulação preliminar, o prazo de entrega dos produtos foi escolhido como duas semanas, de acordo com a prática real da empresa. Além disso, adotou-se um estoque de segurança de três semanas e um tempo de revisão de duas semanas.


Figura 10 – Simulação da política de revisão periódica



Na figura 10, a linha azul representa o estoque inicial da semana após ser reposto. A

linha laranja representa o estoque ao final da semana após as vendas. Segundo a simulação, para as condições iniciais aplicadas, ocorreria perda de 0,25% das vendas. Acompanhando a linha laranja, é possível verificar que o estoque após as vendas semanais raramente ficou próximo de zero, principalmente para as observações mais recentes. Assim, verificou-se que um estoque de segurança de três semanas pareceu ser suficiente para evitar perdas de vendas para a empresa.

Figura 11 – Comparação entre estoque real e estoque simulado por revisão periódica



Na figura 11, é possível verificar que o estoque simulado é significativamente menor que o estoque realizado. Para o período em que existem dados tanto do estoque real quanto do estoque simulado, a soma do estoque simulado representou 10,0% da soma do estoque real. Juntando as informações das figuras 10 e 11, é possível perceber que seria possível diminuir significativamente os níveis de estoque praticados pela empresa e, mesmo assim, manter baixo o risco de perder vendas.

Uma possível preocupação que a Empresa 1 pode apresentar é em relação ao prazo de validade de seus produtos. O tempo de validade dos produtos da Empresa 1 é de aproximadamente 52 semanas. Faz sentido verificar o tempo máximo que um produto passa no estoque antes de ser vendido. Assumindo que a Empresa 1 adota o método *First In, First Out*, no qual produtos mais velhos são vendidos primeiro, o tempo máximo de um produto em estoque na simulação foi de 5 semanas.


5.5.2.2 Acompanhamento constante

Para o método de acompanhamento constante, baseou-se no modelo do sistema mín-máx, explicado na seção de teoria 4. Como os dados foram agrupados semanalmente

por razões já discutidas, o acompanhamento constante acaba apresentando um caráter semanal, mas a aplicação do método para outras granularidades de tempo seria análoga.

Para o cálculo da quantidade de pedido Q , multiplicou-se a demanda prevista pelo tempo de reposição. Para a simulação, novamente adotou-se o prazo de entrega de duas semanas e um estoque de segurança para três semanas.

Figura 12 – Simulação da política mín-máx





Na figura 12, é possível perceber que o estoque pós vendas vendas, indicado pela linha laranja, raramente se aproxima de zero após as observações iniciais, indicando que não houve, durante a simulação, indícios de perda de vendas. Além disso, como indicado pela linha verde, de reposição, essa política de estoque, para as condições impostas, sugere reposições espaçadas.

Na figura 13, é possível ver a comparação entre o estoque realizado e o estoque simulado pela política mín-máx. Novamente, o resultado da simulação indicou níveis de estoque significativamente menores do que os praticados. Para o período em que existem dados tanto do estoque real quanto do estoque simulado, a soma do estoque simulado representou 12,9% da soma do estoque real. Além disso, não ocorreram vendas perdidas na simulação. Por fim, o tempo máximo de um produto em estoque para essa simulação foi de 6 semanas.

Vale ressaltar que a política de estoque mín-máx é suscetível à maneira como se calcula a quantidade de pedido Q . Para demonstrar isso, foi simulada uma outra versão da política mín-máx que calcula Q da maneira sugerida na equação 17. Para simplificação e coerência teórica, assumiu-se que os custos de realização de um pedido eram constantes independente do tamanho do pedido, atribuindo o valor de 5000 unidades de dinheiro para cada pedido. Além disso, assumiu-se que os custos de manutenção de um produto

Figura 13 – Comparação entre estoque real e estoque simulado por mín-máx

Figura 14 – Simulação da política mín-máx com cálculo alternativo de Q 

no estoque representavam 1% do preço do produto a cada semana. Os resultados estão apresentados na figura 14. Na simulação original, haviam sido realizados 22 pedidos de reposição, enquanto na segunda foram realizados 9. A segunda simulação tinha o objetivo de satisfazer a condição de tentar minimizar os custos relacionados à estoque, tanto de aquisição quanto de manutenção. O estoque simulado da simulação com Q alternativo representou 24,6% do estoque real. Além disso, ocorreu a perda de 0,57% das vendas. O tempo máximo de um produto em estoque foi de 10 semanas. Assim, é possível verificar que

de fato a política de reposição mín-máx depende da maneira como se calcula a quantidade de pedido Q e para parâmetros ou cálculos diferentes essa quantidade pode variar bastante.

Neste trabalho, para elaboração de resultados, foi escolhida a maneira de se calcular Q explicada originalmente, pois para as empresas, os custos de aquisição eram proporcionais ao tamanho do pedido.

6 RESULTADOS

6.1 Empresa 1

No capítulo 5, mostrou-se a maneira em que os modelos de política de reposição foram desenvolvidos. Entretanto, a proposta deste trabalho era sugerir reposições de estoque a nível de *SKU*. Portanto, os modelos desenvolvidos foram aplicados aos principais *SKU*'s da Empresa 1 estudada, que representam a parte A da curva ABC. Primeiramente, para determinar o modelo de previsão a ser utilizado para cada *SKU*, foram comparados os modelos de previsão desenvolvidos e seus respectivos erros. As previsões foram calculados para as 20 últimas observações, para que os modelos tivessem dados suficientes de treino antes de serem testados. Para realização das previsões anteriores, utilizou-se o modelo base com $k = 3$. Além disso, os modelos de previsão foram testados para dados fora dos utilizados para desenvolvimento dos modelos e os resultados podem ser encontrados no apêndice A, na tabela 9. As médias dos *MAPEs* dos testes podem ser consultadas na tabela 4.

Tabela 4 – Resultados dos testes para a Empresa 1

Modelo	Média dos MAPEs
Modelo Base	46,7%
Suavização Exponencial	50,7%
ARIMA	57,6%
Melhor modelo para cada SKU	35,0%

A partir das previsões, foi possível simular os níveis de estoque para ambas as políticas de reposição. Nas simulações, levou-se em consideração os custos de perda de vendas e de manutenção do estoque. Para cada política de estoque, verificou-se o estoque de segurança que minimizava a soma dos custos de vendas perdidas e dos custos de manutenção.

$$TC = S_l * C + IL * C * I \quad (34)$$

onde,

TC = custos totais (total costs)

S_l = vendas perdidas (lost sales)

C = custo do item (cost)

IL = nível de estoque (inventory level)

I = taxa de manutenção

Tabela 5 – Políticas de reposição aplicadas aos principais SKU's da Empresa 1

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
1	5.9	38.1	9	2.4	46.1	10
2	2.9	33.5	10	1.7	39.0	11
3	1.6	16.7	8	1.4	20.3	11
4	0.9	24.1	9	0.4	27.4	10
5	8.3	18.8	15	2.4	23.1	17
6	4.1	16.6	10	3.8	20.6	11
7	1.0	57.0	12	1.0	65.5	12
8	2.4	27.2	12	1.0	30.5	12
9	2.6	5.9	7	5.5	7.0	8
10	1.9	26.9	8	2.1	32.6	9
11	0.8	10.2	13	0.7	11.6	14
12	0.9	12.0	13	0.8	16.8	15
13	0.9	15.6	11	0.5	20.6	14
14	3.4	4.9	9	1.0	6.0	12
15	7.6	19.8	17	4.8	21.8	18
16	1.2	12.4	10	1.5	14.4	11
17	3.3	44.4	13	0.8	50.4	15
18	3.8	8.8	15	1.4	9.8	16
19	2.8	27.0	9	0.9	30.3	10
20	11.6	53.3	17	9.1	60.0	18
21	1.1	21.8	10	0.5	27.6	11

Para esses cálculos, considerou-se que a taxa de manutenção de um produto no estoque por semana era de 1% do seu preço e que em caso de perdas de vendas o prejuízo seria a multiplicação entre o preço do produto e o número de vendas perdidas.

Por fim, os parâmetros utilizados para a revisão periódica foram duas semanas entre revisões, duas semanas de tempo de entrega e quatro semanas de estoque de segurança. Os parâmetros utilizados para o acompanhamento constante foram duas semanas de tempo de entrega e quatro semanas de estoque de segurança. Os resultados podem ser conferidos na tabela 5.

Na tabela 5, é possível ver para cada um dos principais *SKU's* a porcentagem de vendas perdidas em relação ao total de vendas realizadas para ambas as políticas de reposição. Além disso, é possível verificar a relação entre o estoque sugerido pelos modelos em relação ao estoque realmente praticado pela empresa e o tempo máximo em que o *SKU* ficou estocado de acordo com as simulações.

Resultados individuais podem ser conferidos na tabela, mas de maneira geral é possível perceber que para ambas as políticas de reposição, a porcentagem de vendas


perdas não é alta. Além disso, ambas as políticas sugerem níveis de estoque abaixo dos que realmente foram praticados, dando indícios de que seria possível reduzir os níveis de estoque da empresa sem grandes impactos nas vendas. Por fim, sabendo que o tempo de validade dos produtos é de 52 semanas, o tempo máximo de um produto no estoque foi satisfatório para todos os *SKU*'s.

Para as condições utilizadas nas simulações da Empresa 1, a política mín-max apresentou um número menor de vendas perdidas e um nível maior de estoque quando comparada à política de revisão periódica. De fato, quanto maior o nível de estoque praticado, menor a chance de perda de vendas. Assim, se o objetivo fosse minimizar o número de vendas perdidas, a política de ponto de estoque seria a indicada por ter apresentado melhores resultados nesse quesito.

Por fim, vale ressaltar que alterando os parâmetros dos modelos de políticas de estoque, seria possível mudar os resultados das simulações. Por exemplo, como alternativa para se evitar perdas de vendas, poderia se escolher um estoque de segurança tão alto quanto se desejasse; mas vale lembrar que isso resultaria em custos de manutenção de estoque mais elevados.

A escolha de qual política de estoque adotar dependeria das prioridades da empresa. Caso a empresa quisesse focar em evitar perdas de vendas, ela poderia focar em métodos de acompanhamento constante dos níveis de estoque como a política mín-max sugerida. Caso a empresa tivesse recursos limitados e não conseguisse rever os níveis do estoque constantemente, uma política de estoque de revisão periódica poderia ser a mais indicada. Além disso, a empresa poderia optar por um misto das políticas de estoque, adotando uma política de estoque de acompanhamento constante para os produtos que mais geram receita e uma política de estoque de revisão periódica para os demais produtos, por exemplo.

Figura 15 – Comparação dos custos de estoque praticado e simulado para a Empresa 1



Constatou-se que, para a Empresa 1, os níveis de estoque da simulação da política de estoque mín-máx, considerando os custos de manutenção de estoque de 1% por semana,

poderiam diminuir os custos de armazenagem e de vendas perdidas em 68,2%. Na figura 15 podemos ver a comparação dos custos praticados e simulados.

6.2 Empresa 2

Para análise preliminar da Empresa 2, nas vendas agrupadas, inicialmente o modelo de previsão utilizado foi o modelo base com $k = 3$. A Empresa 2, assim como a Empresa 1, apresentava um tempo de entrega de produtos de duas semanas, apesar das duas empresas trabalharem em ramos diferentes. Além disso, os produtos da Empresa 2 apresentavam um tempo de validade de 104 semanas. Para as políticas de estoque desenvolvidas, é possível verificar o resultado das simulações de vendas agrupadas na figura 16. Os parâmetros utilizados para as vendas agrupadas foram os mesmos que foram utilizados na Empresa 1. Para evitar perdas de vendas nas observações iniciais, assumiu-se que o estoque inicial dos produtos da empresa era capaz de suprir a demanda das 4 primeiras observações

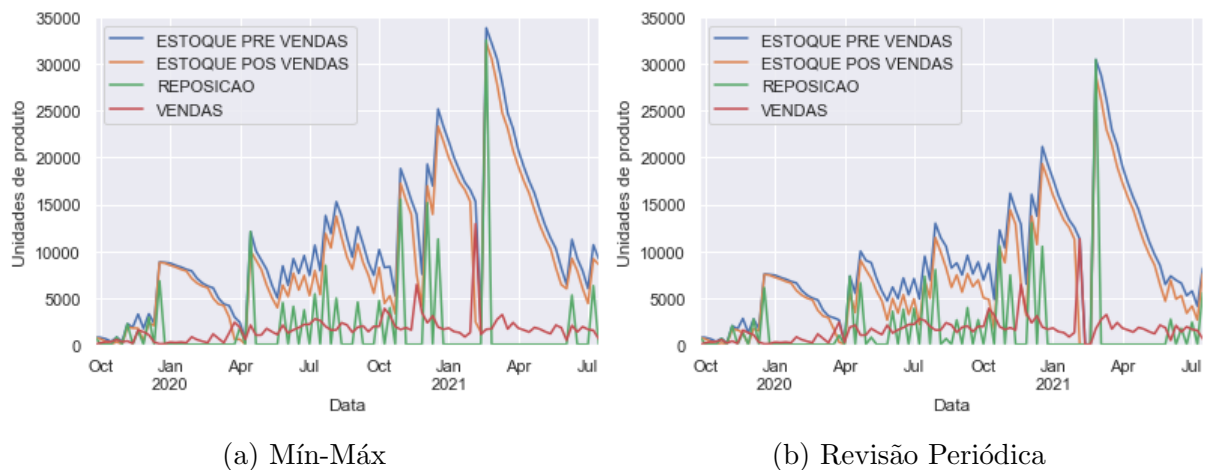


Figura 16 – Simulações para a Empresa 2

Tabela 6 – Resultados dos testes para a Empresa 2

Modelo	Média dos MAPEs
Modelo Base	101,7%
Suavização Exponencial	107,9%
ARIMA	58,0%
Melhor modelo para cada SKU	40,6%

Pela figura 16, é possível ver que para ambas as simulações das políticas de estoque, houve um grande reabastecimento de estoque em fevereiro de 2021. Isso ocorreu devido ao número de vendas elevado que ocorreu na observação anterior ao pico de reabastecimento. Posteriormente, verificou-se que o número elevado de vendas tratava-se de um *outlier*. Como nessas simulações preliminares *outliers* não foram ignorados na elaboração das previsões de demanda, acabaram ocorrendo reabastecimentos maiores do que o necessário.

Essa situação mostra a importância do tratamento de *outliers* como explicado no capítulo 5 de desenvolvimento, assim como destaca a dependência da política de estoque com bons modelos de previsão.

Na figura 17, é possível verificar como os estoques simulados para ambas as políticas de estoque implementadas ficaram comparados com os níveis reais de estoque da Empresa 2. Para a política de estoque de revisão periódica, ocorreu a perda 4,4% das vendas, a relação entre estoque simulado e estoque realizado foi de 30,0% e o tempo máximo de estocagem foi de 16 semanas. Para a política mín-máx, ocorreu a perda de 1,1% das venda e a relação entre o estoque simulado e o estoque real foi de 35,5% e o tempo máximo de estocagem foi de 18 semanas, nos resultados de vendas agrupadas.




Figura 17 – Comparações com o estoque real para a Empresa 2

Novamente, como o objetivo deste projeto era realizar previsões e políticas de reposição à nível de *SKU*, verificou-se para cada *SKU* o melhor modelo de previsão com seus respectivos parâmetros. As média dos *MAPEs* podem ser conferidos na tabela 6 e os resultados dos testes e seus parâmetros ótimos podem ser encontrados na tabela 12 do apêndice. A partir dos modelos de previsão, foi possível realizar as simulações de estoque para cada *SKU*. Verificou-se também que o estoque de segurança que minimizava os custos de perdas de vendas e de manutenção era de duas semanas para ambas as políticas de reposição, considerando o custo de manutenção como 1% a cada semana.


Na tabela 7, é possível ver os resultados das simulações para os *SKU's* que compõem a parte A da curva ABC da Empresa 2, utilizando um estoque de segurança de duas semanas. De maneira geral, ambas as políticas perderam poucas vendas em suas simulações. Ainda assim, como sugerido pelos resultados, uma alteração na política de reposição da Empresa 2 pode levar a níveis menores de estoque sem grandes aumentos nas chances de perdas de vendas.

Por fim, constatou-se que os níveis de estoque da simulação da política de estoque mín-máx poderiam diminuir os custos de armazenagem e de vendas perdidas em 38,2%. Na figura 18 podemos ver a comparação dos custos praticados e simulados.

Tabela 7 – Políticas de reposição aplicadas aos principais SKU's da Empresa 2

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
1	21,1	13,3	20	5,7	16,6	32
2	10,3	13,1	10	3,4	16,1	12
3	31,4	33,2	5	18,5	49,5	4
4	24,3	55,0	22	18,5	55,1	23
5	19,9	99,8	57	16,3	51,6	48
6	5,0	19,0	11	2,7	27,0	13
7	8,2	51,7	17	4,8	55,5	18
8	9,7	18,1	5	5,1	29,7	7
9	0,0	81,0	3	0,0	81,0	3
10	8,6	21,7	12	2,2	31,5	20
11	5,3	36,7	16	1,9	43,8	17
12	6,0	43,6	11	2,5	55,7	13
13	6,9	26,4	11	4,6	24,1	13
14	7,9	18,5	12	14,5	16,8	15
15	13,4	34,2	11	10,0	37,5	13
16	72,0	14,7	5	57,8	12,3	4
17	21,1	53,4	5	13,6	76,8	4
18	4,9	30,0	8	2,8	159,4	19

Figura 18 – Comparação dos custos de estoque praticado e simulado para a Empresa 2



6.3 Empresa 3

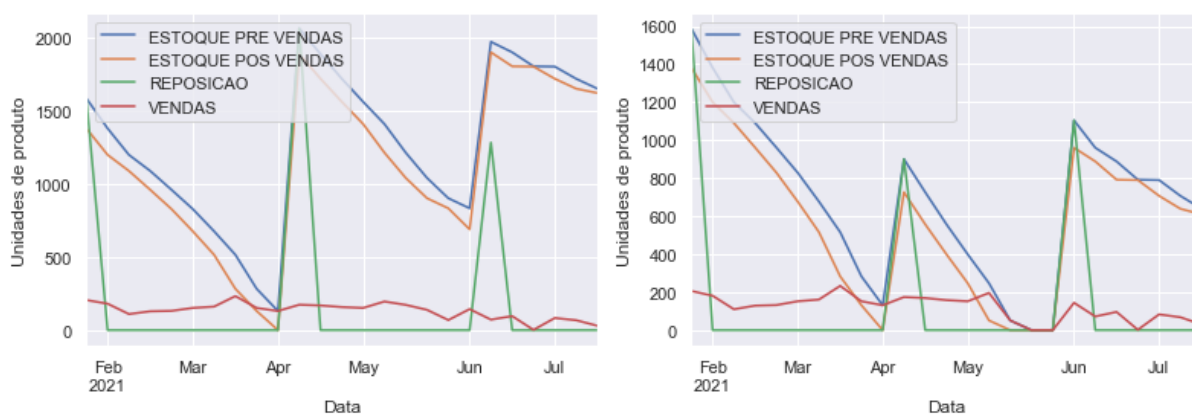
Para a Empresa 3, foi utilizado o modelo de previsão utilizado foi o modelo base com $k = 4$. A Empresa 3 apresentava características diferentes quando comparada

às Empresas 1 e 2. Primeiramente, a Empresa 3 apresentava um tempo de entrega de oito semanas, enquanto as Empresas 1 e 2 apresentavam tempos de duas semanas. A elaboração de uma política de estoque eficiente com tempos de entregas grandes pode ficar comprometida, principalmente se a demanda apresentar um comportamento errático. Além disso, a Empresa 3 trabalha com produtos sem prazos de validade, o que significa que não há grandes problemas para a empresa, do ponto de vista do vencimento de produtos, em estocar grandes quantidades.

A política de estoque adotada na prática pela Empresa 3 consiste em pedidos de grandes quantidades quase sem reposição de estoque. A Empresa 3 parece não apresentar grande preocupação em deixar os seus níveis de estoque zerarem, desde que ela consiga vender todas as unidades de um de seus produtos. As políticas de estoque desenvolvidas neste trabalho, por outro lado, visam manter níveis de estoque capazes de atender à demanda de produtos e evitar perder vendas.

Assim, o contexto em que a Empresa 3 está inserida e o modelo de negócios dela fizeram com que as políticas de reposição deste trabalho não fossem satisfatórias para as necessidades da empresa.

Para elaboração da simulações, considerando o fato de que o tempo de entrega da empresa é de oito semanas, foi necessário assumir que a empresa tinha volume de estoque suficiente para suprir as primeiras observações. Após testes, observou-se que o nível de estoque necessário seria uma quantidade capaz de suprir a demanda das dez primeiras observações. Vale ressaltar, que, caso o nível de estoque tivesse começado zerado, as simulações teriam perdido vendas de maneira garantida.



(a) Mín-Máx

(b) Revisão Periódica

Figura 19 – Simulações para a Empresa 3

Na figura 19, é possível ver a performance das simulações de cada uma das políticas de estoque para as vendas agrupadas da Empresa 3. Na política de estoque mín-máx, não houve perda de vendas e o estoque simulado representou 39,8% do estoque real. Na política de revisão periódica, ocorreu perda de 11,1% das vendas e o estoque simulado representou 19,9% do estoque real.

Na figura 20, é possível perceber a política de estoque adotada pela empresa na prática. Pela linha rosa das figuras, é possível ver as movimentações reais do estoque agrupado da Empresa 3. A partir dela, pode-se perceber que a Empresa 3 opta por estocar seus produtos em quantidades bem maiores do que a sua demanda e faz poucas reposições ao longo do tempo.

Assim, apesar dos resultados satisfatórios nas simulações iniciais, as políticas de estoque desenvolvidas neste trabalho não se aplicam ao contexto da Empresa 3. Para fins de documentação, entretanto, os resultados podem ser encontrados no apêndice A.

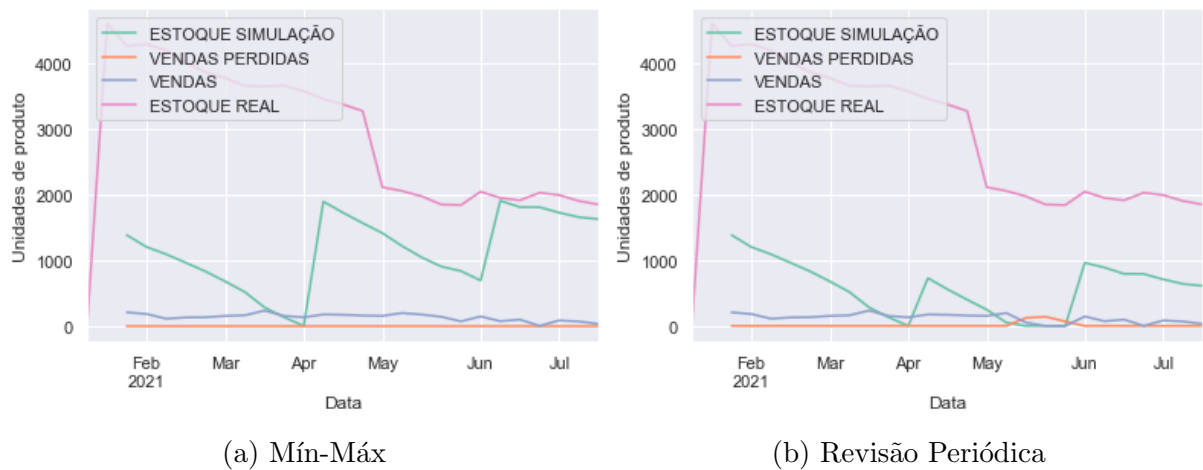


Figura 20 – Comparações com o estoque real para a Empresa 3

7 CONCLUSÃO

A proposta desse trabalho era aprofundar os conhecimentos acerca de previsões de demanda e de políticas de reposição de estoque, através do estudo da literatura e do contato com especialistas da área, visando utilizar o conhecimento técnico dos autores para atacar a dificuldade das empresas de *e-commerce* de gerir seus estoques de maneira rentável.

Através da metodologia proposta pela IBM em (ROLLINS, 2015), foi possível utilizar a ciência de dados para ajudar abordar o problema em mãos. Passando por cada etapa dessa metodologia, o trabalho pôde avançar de maneira ordenada e consciente.

Como resultado, obteve-se que os modelos de previsão de demanda melhoraram o desempenho do modelo base em 80% dos produtos e a diferença entre o *MAPE* do modelo base e o *MAPE* do melhor modelo alternativo é, em média, de 28%.

As políticas de estoque desenvolvidas funcionaram bem para as empresas que apresentavam prazos de entregas curtos e produtos com prazo de validade definido, uma vez que essas empresas possuem interesse em manter níveis de estoque que, sejam ao mesmo tempo capazes de suprir suas demandas, mas que não sejam tão altos a ponto de arriscar o vencimento dos produtos.

Para os produtos da curva A das Empresas 1 e 2, a aplicação da política de estoque mín-máx poderia reduzir os custos relacionados a perda de vendas e a manutenção de estoque em 68,2% e 38,2%, respectivamente. Para a Empresa 3, entretanto, como foi explicado ao longo do trabalho, as políticas de estoque exploradas não se encaixariam no contexto de negócios praticado pela empresa e, portanto, não se pode afirmar que haveria geração de valor ao se aplicá-las.

Deste modo, pode-se afirmar que o trabalho cumpriu seu principal objetivo que era o de trazer modelos que gerassem valor econômico para as empresas que forneceram os dados, através de previsões de demanda mais acuradas que o modelo base e políticas de reposição de estoque eficientes.

É importante considerar que, além de trabalhar com empresas com poucos dados históricos, a natureza do projeto exigiu que as previsões estivessem a nível de *SKU*. Essa alta granularidade diminui ainda mais a eficiência das previsões, pois torna os dados esparsos e nem sempre consistentes.

7.1 TRABALHOS FUTUROS

Como trabalhos futuros, os autores acreditam que seria interessante explorar outros métodos de previsão mais complexos na tentativa de melhorar os resultados apresentados neste trabalho. Além de testar algoritmos mais complexos, os autores acreditam que a

utilização de dados externos poderia contribuir para esse fim. Também seria interessante explorar dados de outras empresas, principalmente empresas que possuem dados de séries históricas mais longas. A motivação para isso seria tentar empregar modelos que levam em conta componentes de sazonalidade.

Um outro trabalho futuro, seria o desenvolvimento de uma interface gráfica própria para facilitar a experiência do usuário e a personalização dos parâmetros. Seria interessante também implementar um sistema para notificar e instruir o usuário quando uma reposição for necessária. Isso auxiliaria na implementação deste projeto em empresas para validação de seus resultados e possibilitaria a utilização para fins comerciais.

7.2 CONSIDERAÇÕES FINAIS

Este trabalho permitiu aos autores utilizar os conhecimentos analíticos adquiridos durante a graduação e aplicá-los em um contexto de negócios, passando pelas etapas de um projeto de ciência de dados.

Foi necessário adquirir o conhecimento de logística e planejamento comercial através não só da literatura, como também de conversas com especialistas no assunto, para que fosse possível entender o problema a fundo e utilizar os conhecimentos técnicos na elaboração da solução. Além disso, o projeto ajudou os autores a consolidar muitos dos conceitos da ciência dos dados, bem como explorar algoritmos e técnicas desse campo do conhecimento.

Por fim, os autores acreditam que o desenvolvimento deste trabalho proporcionou grandes desafios, mas acima de tudo, grandes aprendizados.

Referências

- ABURTO, L.; WEBER, R. Improved supply chain management based on hybrid demand forecasts. **Applied Soft Computing Journal**, v. 7, n. 1, p. 136–144, 2007. ISSN 15684946. Citado na página 7.
- ALI, Ö. G. et al. SKU demand forecasting in the presence of promotions. **Expert Systems with Applications**, v. 36, n. 10, p. 12340–12348, 2009. ISSN 09574174. Citado 2 vezes nas páginas 8 e 14.
- ARROW, K. J.; HARRIS, T.; MARSCHAK, J. Optimal Inventory Policy. **Econometrica**, v. 19, n. 3, jul 1951. ISSN 00129682. Citado na página 18.
- ARUNRAJ, N. S.; AHRENS, D. 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. ISSN 09255273. Citado na página 7.
- AVIV, Y. Collaborative Forecasting and Its Impact on Supply Chain Performance. In: . [S.l.: s.n.], 2004. p. 393–446. Citado na página 6.
- BALLOU, R. H. **Business logistics / supply chain management**. 5. ed. [S.l.: s.n.], 2004. ISBN 978-85-363-0591-2. Citado 3 vezes nas páginas 18, 21 e 22.
- CACHON, G. P.; FISHER, M. Supply chain inventory management and the value of shared information. **Management Science**, v. 46, n. 8, p. 1032–1048, 2000. ISSN 00251909. Citado na página 6.
- DUMBILL, E. et al. **Educating the Next Generation of Data Scientists**. 2013. Citado na página 3.
- FENG, Q.; SHANTHIKUMAR, J. G. How Research in Production and Operations Management May Evolve in the Era of Big Data. **Production and Operations Management**, v. 27, n. 9, p. 1670–1684, 2018. ISSN 19375956. Citado na página 8.
- HAZEN, B. T.; BYRD, T. A. Toward creating competitive advantage with logistics information technology. **International Journal of Physical Distribution & Logistics Management**, v. 42, n. 1, 2012. ISSN 09600035. Citado na página 1.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting: Principles and Practice**. 2018. 421–455 p. Disponível em: <<https://otexts.com/fpp2/index.html>>. Citado na página 14.
- MA, S.; FILDES, R.; HUANG, T. Demand forecasting with high dimensional data: The case of SKU retail sales forecasting with intra- and inter-category promotional information. **European Journal of Operational Research**, v. 249, n. 1, p. 245–257, 2016. ISSN 03772217. Citado na página 8.
- MAURO, A. D.; GRECO, M.; GRIMALDI, M. **A formal definition of Big Data based on its essential features**. 2016. Citado na página 1.
- ROLLINS, J. B. Foundational Methodology for Data Science. **IBM analytics**, IBM, p. 1–4, 2015. Citado 2 vezes nas páginas 11 e 44.

- ROSSUM, G. V.; DRAKE, F. L. **Python 3 Reference Manual**. Scotts Valley, CA: CreateSpace, 2009. ISBN 1441412697. Citado na página 27.
- SEABOLD, S.; PERKTOLD, J. statsmodels: Econometric and statistical modeling with python. In: **9th Python in Science Conference**. [S.l.: s.n.], 2010. Citado na página 29.
- SIVARAJAH, U. et al. Critical analysis of Big Data challenges and analytical methods. **Journal of Business Research**, v. 70, p. 263–286, 2017. ISSN 01482963. Citado na página 3.
- VIEN, B. S. et al. A machine learning approach for anaerobic reactor performance prediction using long short-term memory recurrent neural network. In: **Materials Research Proceedings**. [S.l.: s.n.], 2021. v. 18, p. 61–70. ISBN 9781644901304. ISSN 2474395X. Citado na página 29.
- VOLLMANN, T. E. **Manufacturing planning and control systems for supply chain management**. [S.l.]: McGraw-Hill, 2011. 491–492 p. ISBN 978-0-07-175032-5. Citado na página 4.
- WALLER, M. A.; FAWCETT, S. E. Data science, predictive analytics, and big data: A revolution that will transform supply chain design and management. **Journal of Business Logistics**, v. 34, n. 2, p. 77–84, 2013. ISSN 21581592. Citado 2 vezes nas páginas 1 e 2.
- WANG, G. et al. **Big data analytics in logistics and supply chain management: Certain investigations for research and applications**. 2016. 98–110 p. Citado na página 1.
- YANG, Y.; PAN, B.; SONG, H. Predicting Hotel Demand Using Destination Marketing Organization's Web Traffic Data. **Journal of Travel Research**, v. 53, n. 4, p. 433–447, 2014. ISSN 15526763. Citado na página 7.

Apêndices

APÊNDICE A – Resultados extras

A.1 Empresa 1

Tabela 8 – Políticas de reposição aplicadas SKU's das curvas B e C da Empresa 1

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
22	10,9	59,4	33	6,7	63,7	36
23	2,4	15,1	10	2,4	17,3	11
24	3,7	12,4	10	1,0	15,3	12
25	2,2	14,8	13	1,9	20,5	16
26	4,4	53,3	18	4,2	56,3	19
27	4,8	18,3	10	2,3	24,0	11
28	53,0	6,2	5	2,4	6,2	4
29	9,3	4,8	19	4,6	5,5	22
30	1,6	25,4	16	1,6	23,5	14
31	3,4	22,6	20	3,2	29,2	21
32	4,7	15,3	16	1,7	19,4	20
33	11,6	8,0	16	0,9	10,8	22
34	2,2	58,5	24	22,7	17,1	20
35	27,1	3,9	5	17,3	3,9	4
36	125,9	0,6	5	19,6	0,6	4
37	45,7	1,8	5	10,9	1,8	4
38	34,4	2,0	5	4,9	2,0	4
39	0,0	25,4	28	26,6	10,3	18
40	0,0	52,3	17	19,8	35,3	18
41	0,5	22,7	19	41,2	16,8	20
42	25,0	1,9	5	20,7	1,9	4
43	6,7	62,0	20	3,6	40,5	20
44	50,0	0,9	5	3,8	0,9	4
45	0,0	23,7	26	176,9	8,8	22
46	37,0	53,5	14	68,2	58,1	15
47	11,2	195,9	23	7,2	163,8	24

Tabela 9 – Testes dos modelos de previsão dos principais *SKU*'s da Empresa 1

SKU	Modelo Base: Parâmetro k	Modelo Base: Erro (%)	Suavização Exponencial: Parâmetros α e β	Suavização Exponencial: Erro (%)	ARIMA: Parâmetros p,d,q	ARIMA: Erro (%)
1	14	45,9	0,1 e 0,05	35,8	3, 1, 0	21,2
2	4	41,5	0,1 e 0,05	34,6	4, 0, 3	46,6
3	2	4,6	0,1 e 0,8	87,8	2, 0, 5	23,5
4	13	53,2	0,05 e 0,45	56,2	1, 2, 2	40,3
5	2	54,3	0,1 e 0,65	22,0	0, 2, 2	40,2
6	13	8,6	0,05 e 1,0	40,7	0, 2, 5	26,0
7	2	50,5	0,3 e 0,9	46,2	4, 0, 5	42,3
8	7	26,4	0,1 e 0,05	17,3	5, 2, 4	4,8
9	12	35,7	0,05 e 0,6	23,6	5, 1, 4	46,1
10	5	74,5	0,05 e 0,2	63,2	1, 2, 5	111,4
11	7	28,0	0,05 e 0,15	1,8	1, 3, 5	244,9
12	13	11,0	0,15 e 0,25	16,9	4, 0, 4	9,4
13	7	132,0	0,05 e 0,05	117,6	1, 2, 2	120,6
14	12	57,6	0,05 e 0,15	68,9	0, 1, 1	58,9
15	9	20,6	0,1 e 0,7	65,8	4, 1, 4	19,5
16	4	66,5	0,1 e 0,05	56,8	0, 3, 5	79,9
17	7	71,4	0,05 e 0,85	29,1	5, 1, 5	81,0
18	14	76,8	0,05 e 1,0	78,9	2, 0, 0	82,9
19	2	17,3	0,05 e 0,9	118,0	2, 2, 2	22,1
20	12	62,5	0,05 e 0,4	47,5	3, 2, 5	48,6
21	6	41,2	0,1 e 0,05	35,7	3, 1, 5	40,2

A.2 Empresa 2

Tabela 10 – Políticas de reposição aplicadas SKU's das curvas B e C da Empresa 2 parte 1

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Compa- ração Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Compa- ração Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
19	4.1	38.6	19	3.5	55.2	26
20	6.0	59.4	28	3.3	54.7	29
21	1.6	5.4	4	1.6	5.4	4
22	15.1	130.3	31	16.6	132.8	31
23	13.3	120.8	22	8.4	156.3	29
24	6.4	69.1	27	0.0	82.1	32
25	3.0	47.4	7	1.9	65.5	15
26	0.0	8.7	3	0.0	8.7	3
27	2.0	204.5	15	1.8	243.3	19
28	9.5	205.2	25	4.4	212.3	26
29	9.1	21.5	17	4.5	30.5	28
30	7.1	117.0	34	3.7	109.5	35
31	13.3	82.1	27	5.9	123.3	28
32	0.0	114.0	2	0.0	114.0	2
33	36.4	57.3	31	30.8	60.4	32
34	11.2	20.6	7	7.2	24.6	10
35	1.2	122.9	23	5.1	119.7	24
36	185.9	516.0	21	159.9	582.6	21
37	7.7	184.5	31	12.6	131.6	30
38	0.0	26.7	3	0.0	26.7	3
39	22.6	412.6	16	12.3	442.6	17
40	2.2	85.3	17	0.8	108.9	23
41	99.8	135.0	7	22.3	203.9	8
42	9.3	140.7	25	2.9	152.5	21
43	16.3	189.8	29	20.0	217.5	29
44	6.2	72.9	18	1.7	33.3	12
45	2.0	51.8	21	1.0	34.9	21
46	8.2	8.5	5	3.9	11.4	4
47	2.0	89.5	14	4.0	98.4	15
48	3.1	74.5	17	3.1	81.0	18
49	4.7	82.4	12	2.2	91.1	14

Tabela 11 – Políticas de reposição aplicadas SKU's das curvas B e C da Empresa 2 parte 2

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
50	8.7	641.7	21	7.8	725.8	22
51	13.9	112.5	21	16.3	115.6	22
52	17.0	90.1	17	18.8	82.5	18
53	19.7	141.4	26	19.7	131.9	28
54	3.1	75.0	16	1.1	57.4	17
55	6.2	28.2	11	3.0	8.8	8
56	96.8	169.7	28	95.1	203.4	33
57	9.7	98.8	15	4.7	111.2	16
58	3.7	32.0	7	0.0	264.6	12
59	1.8	105.6	16	3.1	101.8	17
60	0.0	11.9	3	0.0	11.9	3
61	15.2	188.5	28	15.2	184.4	29
62	3.5	204.6	45	2.8	111.8	33
63	7.8	71.9	29	9.0	22.5	17
64	4.3	284.4	52	47.3	283.3	54
65	6.3	174.5	14	4.4	252.0	11
66	8.3	28.0	8	0.0	66.9	8
67	0.0	128.6	58	0.0	161.3	75
68	4.5	346.5	17	1.1	433.0	18
69	13.6	98.7	8	13.6	118.8	8
70	14.7	69.2	16	16.6	74.0	17
71	0.8	49.0	16	1.9	42.7	18
72	0.3	37.5	16	4.0	30.2	15
73	14.1	166.7	17	7.8	174.8	16
74	0.0	90.0	13	5.5	89.9	13
75	0.2	138.9	23	2.2	128.1	25
76	11.3	201.7	12	8.3	183.4	12
77	0.0	363.6	18	6.6	347.6	19
78	106.6	0.8	5	157.1	1.7	4
79	19.9	277.7	29	17.4	320.1	38
80	1.0	1198.0	62	5.1	145.4	41
81	20.4	120.8	30	3.5	144.7	31
82	0.7	165.9	55	148.2	51.2	36
83	11.4	52.8	17	0.0	209.0	17
84	0.0	128.6	51	1027.8	64.0	45
85	51.6	51.2	36	444.7	10.8	31
86	29.0	247.0	29	55.3	254.4	29
87	17.7	148.5	22	18.8	182.6	28
88	0.0	137.4	59	0.0	173.0	70

Tabela 12 – Testes dos modelos de previsão dos principais *SKU*'s da Empresa 2

SKU	Modelo Base: Parâmetro k	Modelo Base: Erro %	Suavização Exponencial: Parâmetros α e β	Suavização Exponencial: Erro %	ARIMA: Parâmetros p,d,q	ARIMA: Erro %
1	12	74,8	0,05 e 0,5	20,9	2, 0, 0	62,3
2	2	17,9	0,55 e 0,55	49,8	0, 0, 3	22,4
3	7	147,6	0,2 e 0,85	163,9	1, 0, 0	0,9
4	2	101,9	0,05 e 1,0	150,0	3, 0, 5	122,5
5	14	88,0	0,05 e 0,05	46,2	4, 0, 1	68,0
6	6	85,5	0,05 e 0,35	9,6	2, 0, 5	50,7
7	7	147,1	0,05 e 0,05	265,1	1, 0, 0	18,0
8	11	134,4	0,2 e 0,1	102,4	0, 0, 1	82,9
9	2	123,9	0,4 e 1,0	103,7	5, 1, 0	207,7
10	2	23,8	0,05 e 0,15	105,9	1, 0, 0	22,6
11	8	107,3	0,05 e 0,05	189,9	3, 0, 3	59,0
12	14	177,4	0,05 e 0,25	210,9	4, 0, 0	61,0
13	14	223,7	0,05 e 0,3	115,1	0, 0, 1	44,3
14	14	82,7	1,0 e 1,0	53,0	1, 0, 0	76,5
15	6	69,9	0,1 e 0,4	30,4	3, 0, 2	50,2
16	2	158,3	1,0 e 0,1	250,2	0, 0, 1	7,2
17	6	55,0	0,3 e 0,25	41,3	1, 0, 0	55,6
18	7	11,0	0,3 e 0,2	33,2	4, 1, 3	31,8

A.3 Empresa 3

Para empresa 3, ocorreram lacunas em alguns resultados. Nesses casos, não havia dados suficientes para gerar resultados.

Tabela 13 – Políticas de reposição aplicadas aos principais SKU's da Empresa 3

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
1	0,0	833,3	8	0,0	833,3	8
2	129,6	16,8	11	77,1	191,2	10
3	30,0	22,2	11	8,3	21,3	10
4	42,4	10,1	11	18,3	17,4	10
5	0,0	44,8	12	0,0	37,9	12
6	29,8	60,8	13	13,5	119,9	13
7	4,2	87,2	12	0,0	72,8	10
8	0,0	266,7	7	0,0	266,7	7
9	0,0	21,8	15	0,0	15,2	15
10	40,9	37,3	11	8,8	78,7	12
11	22,2	18,7	11	37,5	9,2	17
12	5,3	35,0	10	5,3	35,0	10
13	5,4	141,3	12	5,4	647,1	12
14	11,1	118,2	11	0,0	209,1	10
15	200,0	225,0	11	200,0	225,0	11
16	0,0	7,3	3	0,0	7,3	3
17	0,0	150,0	3	0,0	150,0	3
18	0,0	14,9	6	0,0	14,9	6
19	16,7	292,3	11	16,7	292,3	11
20	10,0	97,7	12	10,0	97,7	12
21	0,0	135,0	5	0,0	135,0	5
22	4,3	34,0	11	0,0	51,5	12
23	0,0	258,1	17	400,0	0,0	18
24	15,4	84,4	11	7,1	268,8	10
25	11,1	21,3	11	11,1	26,0	11
26	0,0	875,0	6	0,0	875,0	6
27	0,0	7,0	12	0,0	8,4	12
28	100,0	0,0	10	100,0	0,0	10

Tabela 14 – Políticas de reposição aplicadas SKU's das curvas B e C da Empresa 3

SKU	Revisão Periódica: Vendas perdidas (%)	Revisão Periódica: Comparação Estoque (%)	Revisão Periódica: Tempo máximo em estoque (Semanas)	Min-Máx: Vendas perdidas (%)	Min-Máx: Comparação Estoque (%)	Mín-Máx: Tempo máximo em estoque (Semanas)
29	0,0	85,0	5	0,0	85,0	5
30	0,0	66,7	6	0,0	66,7	6
31	0,0	177,6	9	0,0	177,6	9
32	40,0	7,1	11	133,3	4,4	12
33	16,7	43,2	11	55,6	94,2	15
34	-	-	-	-	-	-
35	0,0	72,2	11	33,3	44,4	12
36	0,0	80,0	4	0,0	80,0	4
37	25,0	14,3	11	66,7	0,0	12
38	0,0	255,6	12	0,0	611,1	12
39	0,0	65,5	17	0,0	148,3	17
40	0,0	450,0	5	0,0	450,0	5
41	0,0	4,4	15	0,0	1,9	15
42	0,0	105,6	9	0,0	105,6	9
43	0,0	101,0	18	0,0	226,0	18
44	0,0	150,0	6	0,0	150,0	6
45	0,0	71,8	18	40,0	0,0	19
46	0,0	60,0	9	0,0	60,0	9
47	25,0	100,0	16	17,6	103,0	10
48	0,0	16,0	12	50,0	3,7	13
49	0,0	657,1	14	200,0	0,0	15
50	0,0	57,6	11	20,0	24,2	12
51	0,0	20,0	4	0,0	20,0	4
52	0,0	100,0	5	0,0	100,0	5
53	0,0	92,0	12	25,0	0,0	13
54	0,0	1125,0	16	0,0	2875,0	16
55	-	-	-	-	-	-
56	0,0	362,5	11	0,0	1037,5	11
57	0,0	55,6	5	0,0	55,6	5
58	11,1	18,4	10	11,1	18,4	10
59	0,0	33,3	3	0,0	33,3	3
60	0,0	180,0	14	0,0	145,7	14

Tabela 15 – Testes dos modelos de previsão dos principais *SKU*'s da Empresa 3

SKU	Modelo Base: Parâmetro k	Modelo Base: Erro %	Suavização Exponencial: Parâmetros α e β	Suavização Exponencial: Erro %	ARIMA: Parâmetros p,d,q	ARIMA: Erro %
1	-	-	-	-	-	-
2	2	117,9	0,05 e 0,45	21,4	0, 0, 2	64,5
3	5	41,5	0,15 e 1,0	25,1	4, 1, 0	39,7
4	8	5,8	0,15 e 0,75	47,4	0, 0, 2	89,8
5	7	42,9	0,3 e 0,25	0,8	1, 1, 0	0,0
6	4	22,2	0,2 e 0,2	11,2	5, 0, 1	59,0
7	2	75,0	0,5 e 1,0	119,5	2, 1, 2	85,6
8	14	96,2	0,1 e 0,05	95,8	2, 1, 2	97,8
9	-	-	-	-	-	-
10	2	83,3	0,05 e 1,0	153,1	0, 0, 0	100,0
11	2	100,0	0,2 e 0,4	81,8	3, 3, 3	80,9
12	-	-	-	-	-	-
13	7	14,3	0,65 e 0,1	26,2	2, 0, 1	0,3
14	-	-	-	-	-	-
15	10	75,0	0,25 e 0,9	1,2	2, 1, 1	100,0
16	-	-	-	-	-	-
17	-	-	-	-	-	-
18	-	-	-	-	-	-
19	9	11,1	0,35 e 0,2	50,0	2, 0, 1	1,9
20	10	53,5	0,4 e 0,25	31,5	2, 0, 0	77,6
21	-	-	-	-	-	-
22	14	73,4	0,15 e 0,6	95,3	0, 1, 2	67,6
23	-	-	-	-	-	-
24	-	-	-	-	-	-
25	14	57,1	0,2 e 0,95	71,0	1, 1, 5	32,1
26	-	-	-	-	-	-
27	10	23,2	0,25 e 0,25	5,2	3, 1, 5	20,3
28	-	-	-	-	-	-