

UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO TECNOLÓGICO
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO E SISTEMAS
CURSO ENGENHARIA DE PRODUÇÃO MECÂNICA

Felipe Vieira Leandro da Silva

**Projeções de Receitas Líquidas de Empresas de Capital Aberto do Subsetor de
Comércio com Diferentes Metodologias Preditivas em Cenário de Pandemia**

Florianópolis

2021

Felipe Vieira Leandro da Silva

**Projeções de Receitas Líquidas de Empresas de Capital Aberto do Subsetor de
Comércio com Diferentes Metodologias Preditivas em Cenário de Pandemia**

Trabalho Conclusão do Curso de Graduação em Engenharia de Produção Mecânica do Centro Tecnológico da Universidade Federal de Santa Catarina como requisito para a obtenção do título de Engenharia, área Mecânica, habilitação Produção Mecânica

Orientador: Prof. Daniel Christian Henrique

Florianópolis

2021

Ficha de identificação da obra

Vieira Leandro da Silva, Felipe

Projeções de receitas líquidas de empresas de capital aberto do subsetor de comércio com diferentes metodologias preditivas em cenário de pandemia / Felipe Vieira Leandro da Silva ; orientador, Daniel Christian Henrique, 2021.
90 p.

Trabalho de Conclusão de Curso (graduação) -
Universidade Federal de Santa Catarina, Centro Tecnológico,
Graduação em Engenharia de Produção Mecânica, Florianópolis,
2021.

Inclui referências.

1. Engenharia de Produção Mecânica. 2. Engenharia de Produção. 3. Análise de dados. 4. Subsetor de comércio. 5. Previsão de demanda. I. Christian Henrique, Daniel. II. Universidade Federal de Santa Catarina. Graduação em Engenharia de Produção Mecânica. III. Título.

Felipe Vieira Leandro da Silva

**Projeções de Receitas Líquidas de Empresas de Capital Aberto do Subsetor de
Comércio com Diferentes Metodologias Preditivas em Cenário de Pandemia**

Este Trabalho Conclusão de Curso foi julgado adequado para obtenção do Título de Engenheiro Mecânico com habilitação em Produção Mecânica e aprovado em sua forma final pelo Curso de Engenharia de Produção Mecânica

Florianópolis, 16 de Setembro de 2021.

Prof. Mônica Maria Mendes Luna, Dra.
Coordenadora do Curso

Banca Examinadora:

Prof. Daniel Christian Henrique, Dr.
Orientador
Universidade Federal de Santa Catarina

Prof. Rogério Feroldi Miorando, Dr.
Avaliador
Universidade Federal de Santa Catarina

Prof. Ricardo Villarroel Dávalos, Dr.
Avaliador
Universidade Federal de Santa Catarina

Este trabalho é dedicado aos meus amigos
e aos meus queridos pais.

AGRADECIMENTOS

Gostaria de agradecer a minha família, especialmente aos meus pais que forneceram todo o apoio e oportunidades para que eu formasse a minha educação e valores.

Aos meus amigos que tornaram a minha jornada na universidade mais leve e me apoiaram em todas as dificuldades que tive.

Ao meu orientador, prof. Daniel Christian Henrique, que me auxiliou na escolha do tema deste trabalho e por todas as reuniões de orientações e conhecimento que me motivaram para finalizar este trabalho.

A todas as entidades que fizeram parte da minha jornada profissional, em especial ao Grupo de Estudos em Lean (GLean) que me forneceu oportunidades de estágios imensuráveis para a minha formação pessoal e profissional.

Ao corpo técnico do departamento de Engenharia de Produção pelo apoio nos problemas relacionados à graduação e aos demais professores do departamento por todo o conhecimento dado.

“Conhecimento não tem valor a menos que você o coloque em prática.”

(Anton Chekhov)

RESUMO

O planejamento das vendas no subsetor de comércio no Brasil tem sua complexidade associada às peculiaridades que o caracterizam tais como: variações dos canais de vendas utilizados pelos consumidores, forte sazonalidade, entrada de competidores nacionais e internacionais entre outros. Nesse contexto, a previsão de vendas possui uma enorme importância no planejamento de uma organização e conseguir a maior acuracidade nesta atividade revela-se como um valioso recurso estratégico capaz contribuir para a necessária manutenção de sua competitividade. Com o passar dos anos houve um grande avanço na tecnologia de coleta e tratamento de dados e em conjunto diversos modelos estatísticos preditivos foram ganhando destaque para serem aplicados em cenários cada vez mais complexos. Métodos de previsões são usados para identificar padrões em séries temporais e tem a capacidade de prever períodos futuros com acuracidade cada vez maior. No final do ano de 2019, a economia mundial foi impactada com a pandemia da COVID-19 e o subsetor de comércio foi amplamente impactado pelo fechamento de diversos pontos comerciais e uma forte migração dos consumidores para o e-commerce. Todo esse impacto trouxe uma complexidade ainda maior aos gestores para conseguirem prever demandas futuras e tomarem decisões estratégicas. O presente trabalho se propõe em aplicar diferentes metodologias preditivas nas principais empresas de capital aberto do subsetor de comércio usando as séries temporais da receita operacional líquida levando em consideração o impacto da pandemia. A conclusão desse estudo quantitativo se faz com a comparação de acuracidade entre os modelos.

Palavras-chave: Previsão de demanda; análise de dados; séries temporais ; comércio; teste de acuracidade.

ABSTRACT

Sales planning in retail business in Brazil has its complexity associated with the peculiarities that characterize it such as: variations in the sales channels used by consumers, strong seasonality, entry of national and international competitors, among others. In this context, sales forecast has an enormous importance in the planning of an organization and achieving the greatest accuracy in this activity reveals itself as a valuable strategic resource capable of contributing to the necessary maintenance of its needs. Over the years, there has been a great advance in data collection and processing technology and, together, several predictive statistical models have been gaining prominence to be applied in increasingly complex scenarios. Forecasting methods are used to identify patterns in time series and have the ability to predict future values with increasing accuracy. At the end of 2019, the world economy was impacted by the COVID-19 pandemic and the retail subsector was largely impacted by the closure of several commercial points and a strong migration of consumers to e-commerce. All this impact brought even greater complexity to managers to be able to predict future demands and make strategic decisions. This work proposes to apply different predictive methodologies in the biggest retail publicly traded companies in retail subsector using the time series of net operating revenue given how the impact of the pandemic. The conclusion of this quantitative study is made with an accuracy comparison between the models.

Keywords: Forecasting; data analysis; time series; retail; accuracy test.

LISTA DE FIGURAS

Figura 1	Etapas do método de trabalho	34
Figura 2	Volume de vendas no comércio varejista do Brasil.....	37
Figura 3	Histórico do faturamento no e-commerce brasileiro.	38
Figura 4	Participação do e-commerce nas vendas do Magazine Luiza S.A nos últimos trimestres.....	38
Figura 5	Receita Operacional Líquida - Magazine Luiza S.A	40
Figura 6	Receita Operacional Líquida - Via Varejo S.A	41
Figura 7	Receita Operacional Líquida - Americanas S.A	42
Figura 8	Receita Operacional Líquida - Lojas Renner S.A.....	42
Figura 9	Decomposição da receita operacional líquida da Magazine Luiza S.A.....	44
Figura 10	Previsão da receita operacional líquida (em mil R\$) para Magazine Luiza S.A por Média Móvel Centrada	45
Figura 11	Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Magazine Luiza S.A.....	46
Figura 12	Previsão SARIMA da receita operacional líquida (em mil R\$) para Magazine Luiza S.A.....	47
Figura 13	Comparação entre os modelos preditivos (em mil R\$) para Magazine Luiza S.A	47
Figura 14	Decomposição da receita operacional líquida da Via Varejo S.A.....	48
Figura 15	Previsão da receita operacional líquida (em mil R\$) para Via Varejo S.A por Média Móvel Centrada	49
Figura 16	Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Via Varejo S.A.....	49
Figura 17	Previsão SARIMA da receita operacional líquida (em mil R\$) para Via Varejo S.A.....	50
Figura 18	Comparação entre os modelos preditivos (em mil R\$) para Via Varejo S.A	50
Figura 19	Decomposição da receita operacional líquida da Americanas S.A.....	52
Figura 20	Previsão da receita operacional líquida (em mil R\$) para Americanas S.A por Média Móvel Centrada	52

Figura 21	Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Americanas S.A	53
Figura 22	Previsão SARIMA da receita operacional líquida (em mil R\$) para Americanas S.A	54
Figura 23	Comparação entre os modelos preditivos (em mil R\$) para Americanas S.A	54
Figura 24	Decomposição da receita operacional líquida da Lojas Renner S.A	55
Figura 25	Previsão da receita operacional líquida (em mil R\$) para Lojas Renner S.A por Média Móvel Centrada	56
Figura 26	Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Lojas Renner S.A	57
Figura 27	Previsão SARIMA da receita operacional líquida (em mil R\$) para Lojas Renner S.A	58
Figura 28	Comparação entre os modelos preditivos (em mil R\$) para Lojas Renner S.A	58
Figura 29	Vendas do comércio nos últimos 12 meses.	60

LISTA DE TABELAS

Tabela 1	Número de artigos encontrados nas bases de dados por palavras-chave... 19
Tabela 2	Número de artigos encontrados nas bases de dados por palavras-chave... 20
Tabela 3	Teste de Acuracidade da Magazine Luiza S.A 48
Tabela 4	Teste de Acuracidade da Via Varejo S.A 51
Tabela 5	Teste de Acuracidade da Americanas S.A..... 55
Tabela 6	Teste de Acuracidade da Lojas Renner S.A..... 59

LISTA DE ABREVIATURAS E SIGLAS

MAE	<i>Mean Absolut Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
RMSE	<i>Root Mean Squared Error</i>
IBGE	Instituto Brasileiro de Geografia e Estatística
SARIMA	<i>Seasonal Autoregressive Integrated Moving Average</i>
AIC	<i>Aikaike information criterion</i>
BIC	<i>Bayesian information criterion</i>
B3	Brasil, Bolsa e Balcão

SUMÁRIO

1	INTRODUÇÃO	15
2	JUSTIFICATIVA	17
2.1	OBJETIVOS.....	17
2.1.1	Objetivo geral	17
2.1.2	Objetivos específicos	17
2.2	LIMITAÇÕES DO TRABALHO	18
2.3	ESTRUTURA DO TRABALHO	18
3	REFERENCIAL TEÓRICO	19
3.1	REVISÃO BIBLIOGRÁFICA.....	19
3.2	DESIGN DE PESQUISA	21
3.3	PREVISÃO DE DEMANDA.....	22
3.4	SÉRIES TEMPORAIS	23
3.5	METODOLOGIAS DE PREVISÃO	23
3.5.1	Regressão linear simples	23
3.5.2	Regressão linear múltipla	24
3.5.3	Média móvel centrada	25
3.5.4	Suavização exponencial	25
3.5.5	Método Holt-Winters	26
3.5.6	Box-Jenkins (ARIMA)	27
3.6	MEDIDAS DE ERRO DE PREVISÃO	29
3.6.1	Erro absoluto médio (MAE)	29
3.6.2	Erro percentual médio (MPE)	29
3.6.3	Erro percentual absoluto médio (MAPE)	30
3.6.4	U de theil	31
3.6.5	Raiz do erro quadrático médio (RMSE)	31
4	PROCEDIMENTOS METODOLÓGICOS	33
4.1	CLASSIFICAÇÃO DA PESQUISA.....	33
4.2	CARACTERIZAÇÃO DO MÉTODO DE TRABALHO.....	34
5	DESENVOLVIMENTO	36
5.1	DEFINIÇÃO DO PROBLEMA	36
5.2	COLETA DOS DADOS	39

5.3	SELEÇÃO DO PACOTE COMPUTACIONAL	39
5.4	ANÁLISE PRELIMINAR	40
5.5	ESCOLHA E IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO	43
5.5.1	Aplicação dos modelos estatísticos	43
5.5.1.1	<i>Magazine luiza S.A.</i>	43
5.5.1.2	<i>Via varejo S.A.</i>	48
5.5.1.3	<i>Americanas S.A.</i>	51
5.5.1.4	<i>Lojas renner S.A.</i>	55
5.6	VALIDAÇÃO DAS CONCLUSÕES	59
6	CONCLUSÕES E RECOMENDAÇÕES	61
	REFERÊNCIAS	63
	APÊNDICE A – MODELOS ARIMA ANALISADOS E BEST MODEL -	
	MAGAZINE LUIZA S.A.	67
	APÊNDICE B – MODELO HOLT-WINTERS - MAGAZINE LUIZA S.A.	72
	APÊNDICE c – MODELO média móvel centrada - MAGAZINE LUIZA S.A.	73
	APÊNDICE D – MODELOS ARIMA ANALISADOS E BEST MODEL – VIA	
	VAREJO S.A.	74
	APÊNDICE E – MODELO HOLT-WINTERS – VIA VAREJO S.A.	77
	APÊNDICE F – MODELO MÉDIA MÓVEL CENTRADA – VIA VAREJO S.A	
	78
	APÊNDICE G – MODELOS ARIMA ANALISADOS E BEST MODEL –	
	AMERICANAS S.A.	79
	APÊNDICE H – MODELO HOLT-WINTERS – AMERICANAS S.A.	83
	APÊNDICE I – MODELO MÉDIA MÓVEL CENTRADA – AMERICANAS S.A	
	84
	APÊNDICE J – MODELOS ARIMA ANALISADOS E BEST MODEL – LOJAS	
	RENNER S.A.	85
	APÊNDICE K – MODELO HOLT-WINTERS – LOJAS RENNER S.A.	88
	APÊNDICE L – MODELO MÉDIA MÓVEL CENTRADA – LOJAS RENNER	
	S.A.	89

1 INTRODUÇÃO

As empresas estão em constante conflito no que se refere à competitividade para garantir a sua sobrevivência. Somado a esse ambiente de conflito existe a alta complexidade de conseguir prever corretamente o comportamento do cliente e sua demanda. São inúmeras variáveis que afetam esse comportamento e ter um bom planejamento e direcionamento estratégico podem ser fatores cruciais que garantem vantagem no ambiente de negócios ao entregar valor para o cliente, com o melhor gerenciamento possível dos recursos produtivos disponíveis.

Em relação à previsão de demanda, muitos fatores financeiros são levados em conta como por exemplo disponibilidade de produtos em estoque que podem ser enviados ao cliente imediatamente e também a capacidade produtiva para abastecer esses estoques ou para enviar diretamente ao cliente final. E essa é a grande complexidade, pois estoque em excesso pode levar a altos custos logísticos. Por outro lado, estoque em falta pode gerar vendas perdidas. Por isso é tão importante possuir um bom método de previsão de demanda e planejamento dos recursos (BOWERSOX e CLOSS, 2009).

Nas empresas do segmento de comércio, a previsão de demanda possui um papel crucial no modelo de negócio. O comportamento do cliente possui algumas características nesse setor que tornam ainda mais complexo conseguir prever com eficiência, como por exemplo sazonalidade e tendência (MAYER, 1990).

O ano de 2020 foi marcado pela rápida disseminação da COVID-19 em todo o mundo. Os efeitos da pandemia junto ao preexistente baixo dinamismo das atividades econômicas atingiram fortemente a economia brasileira (OECD, 2020). O setor de comércio foi impactado de forma bastante peculiar pois no início de 2020 as empresas tiveram que fechar muitos dos canais de vendas físicos em decorrência do distanciamento social, mas ao mesmo tempo levou uma forte migração dos consumidores aos canais de venda digitais. Todo esse cenário imprevisível e de mudanças de comportamento do consumidor trouxe uma grande complexidade para essas empresas conseguirem projetar demandas futuras. Além disso, o fim da pandemia continua muito incerto devido ao aparecimento de novas variantes do COVID-19 pelo Brasil e no mundo (AQUINO *et al*, 2020). Por isso, o presente estudo levou em consideração um cenário em que a população continuará tomando medidas de prevenção, incluindo prioridade a compras online em razão do possível avanço das novas variantes, apesar da queda dos casos de contaminação com as cepas originais frente a vacinação em massa.

Assim, as principais empresas de comércio continuariam se favorecendo do aquecimento no e-commerce e aumento nas vendas.

Com o avanço da tecnologia e das análises de dados, diversos métodos de previsões de demanda para diferentes tipos de atuação das organizações e processos produtivos foram consolidados e disponibilizados. Com isso, muitos gestores varejistas possuem dificuldade em determinar qual seria o melhor método e qual lhe traria informações que representam a realidade de seu mercado de atuação.

2 JUSTIFICATIVA

A motivação desse estudo se baseia em auxiliar nas tomadas de decisão no que se refere à previsão de demanda das corporações de capital aberto do segmento de comércio ao se analisar as projeções de suas receitas operacionais líquida. Além disso, a tecnologia tem sido uma grande aliada em modelar e analisar essas previsões e, em decorrência de sua importância, esse trabalho busca fazer a comparação entre métodos já existentes com o uso de softwares estatísticos.

2.1 OBJETIVOS

2.1.1 Objetivo geral

O objetivo deste estudo é comparar projeções de receita para os próximos dois anos em cenário de pandemia de empresas de capital aberto do segmento de comércio com diferentes metodologias de previsão.

2.1.2 Objetivos específicos

- a) Utilizando métodos de previsão mencionados por Hanke et al. (2001), escolher técnicas de previsão de demanda para séries temporais;
- b) Realizar a previsão para um período futuro de 24 meses dentro do contexto da pandemia com base de dados disponibilizados pelas principais empresas de capital aberto do segmento de comércio;
- c) Comparar os métodos estatísticos utilizando-se de métricas de acuracidade.
- d) Definir qual o melhor modelo para cada caso. Em caso de diferentes modelos forem eleitos como o melhor a partir de diferentes métricas de acuracidade na mesma empresa, avaliar as diferenças entre as previsões para otimizar a escolha do analista

2.2 DELIMITAÇÕES DO TRABALHO

O presente trabalho propõe-se a prever a receita operacional líquida não consolidada das empresas com base no histórico dos períodos anteriores. Ou seja, apenas os dados das empresas controladoras de cada grupo empresarial. Sendo assim, informações como receitas provindas de outras empresas que fazem parte do grupo empresarial e que não sejam a empresa controladora não são levadas em consideração. A decisão tomada por este trabalho dessa limitação é porque essa é a opção mais tradicional de análise, eliminando desta forma vieses nas análises originadas na possível existência de empresas deficitárias dentro do grupo ou que estejam em recuperação judicial.

2.3 ESTRUTURA DO TRABALHO

O trabalho está dividido em seis capítulos. No primeiro é apresentada a introdução ao tema e a contextualização do assunto abordado.

No segundo capítulo é explorado a justificativa para o desenvolvimento do trabalho, os objetivos gerais e específicos e também as limitações do trabalho.

No terceiro capítulo é feito o referencial teórico do tema e depois os principais conceitos que servem de base para o entendimento do trabalho.

O quarto capítulo explora o procedimento metodológico da pesquisa deste estudo, assim como o enquadramento do tipo de pesquisa.

O desenvolvimento da metodologia de pesquisa explorada no capítulo anterior é explorado no quinto capítulo. Toda a análise dos dados, escolha e implementação dos modelos preditivos e conclusões dos resultados é explorada neste capítulo.

No sexto e último capítulo tem-se as conclusões derivadas dos resultados obtidos e são sugeridas recomendações para trabalhos futuros.

3 REFERENCIAL TEÓRICO

Neste capítulo serão explorados os conceitos teóricos que auxiliam no entendimento da análise do problema. Na primeira parte será apresentada a revisão da literatura de estudos relacionados ao presente trabalho. Em seguida, são expostos os conceitos de modelos de inferência estatística e de predição.

3.1 REVISÃO BIBLIOGRÁFICA

A revisão bibliográfica deste trabalho tem o intuito de identificar qual o estado da arte em termos de análises preditivas no segmento de comércio utilizando modelos preditivos de previsão de demanda.

As bases de dados escolhidas para o trabalho foram: Economatica, Google Scholar, IEEE Xplore e Science Direct por tratarem-se de bases conhecidas no meio da Engenharia e Economia. As palavras-chave foram direcionadas em termos relacionados à previsão de demanda no segmento de comércio e varejo.

Após a definição de algumas palavras-chave que direcionam o foco do estudo, fez-se o levantamento quantitativo destas nas bases anteriormente selecionadas. Os resultados da busca são mostrados na Tabela 1.

Tabela 1 — Número de artigos encontrados nas bases de dados por palavras-chave.

Palavras-chave	IEEE Xplore	Google Scholar	Science Direct
<i>Sales Forecast</i>	929	892.000	59.006
<i>Retail company</i>	1.000	2.750.000	75.492
<i>Net Operating Income</i>	62	1.690.000	53.563

Fonte: Elaborado pelo autor (2021).

Foram escolhidos alguns artigos com base na proximidade do título com o tema abordado no trabalho. A tabela 2 lista esses artigos selecionados, bem como seus autores e ano de publicação.

Tabela 2 — Número de artigos encontrados nas bases de dados por palavras-chave.

Título	Autor (Ano)
Modelo de Previsão de Faturamento Diário de uma Empresa de Varejo	TEIXEIRA (2014)
DEFINIÇÃO DE UM MODELO DE PREVISÃO DAS VENDAS DA REDE VAREJISTA ALPHABETO	SILVA (2008)
A hybrid SARIMA wavelet transform method for sales forecasting	CHOI et al. (2011)
A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting	ARUNRAJ et al. (2015)
Demand forecasting in food retail: a comparison between the HoltWinters and ARIMA models	DA VEIGA et al. (2014)

Fonte: Elaborado pelo autor (2021).

No seu artigo, Teixeira (2014) aplica modelos preditivos em uma empresa varejista farmacêutica analisando o faturamento no intervalo de 5 anos nas 125 lojas da rede. Para acompanhar a variabilidade mensal do faturamento foram usados os modelos Auto-regressivos Integrado de Médias Móveis Sazonais (SARIMA) e o método de Alisamento Exponencial de Winter Aditivo (AEWA). Para realizar a comparação entre os modelos foram utilizados a Soma do Quadrado dos Resíduos (SSR), o Critério de Informação de Akaike (AIC) e o Critério Bayesiano de Informação de Schwarz (BIC).

O estudo de Silva (2008) realizado em uma empresa do setor de vestuário infantil permitiu fazer a comparação de desempenho entre diferentes métodos preditivos, sendo eles o Sazonal Aditivo de Winters, Sazonal Multiplicativo de Winters e Box-Jenkins. A partir da base histórica de vendas e após realizar as previsões foi possível utilizar diferentes indicadores baseados nos tipos de erros de previsão e concluiu-se que, nesse caso específico, o método Box-Jenkins obteve melhor desempenho.

Choi et al. (2011) realizaram um estudo ao comparar diferentes métodos de previsão utilizando dados de uma empresa de roupas e propõem um novo modelo híbrido de previsão que combina o método SARIMA e Transformada Wavelet. O estudo analisou dados reais de vendas, assim como também dados hipotéticos e conjuntos de dados disponíveis publicamente e concluíram que esse método híbrido é altamente aplicado para previsão de demanda nesse setor.

Arunraj et al. (2015) desenvolveram um modelo híbrido de previsão de demanda no setor de alimentos perecíveis. Nesse tipo de setor é crucial aplicar bons modelos preditivos em

decorrência da sensibilidade da validade dos alimentos. Além disso, de acordo com os autores, as séries temporais na indústria de varejo alimentício são caracterizadas por alta volatilidade e assimetria, que variam com o tempo. Então, previsões constantes são exigidas pelas empresas de varejo para definir uma política de estoque apropriada.

Da Veiga et al. (2014) realizam uma comparação de desempenho entre os modelos de previsão de demanda SARIMA e Holt-Winters (HW) utilizando séries temporais das vendas de uma empresa do setor de laticínios do Brasil. Como métricas de performance foram utilizadas o Erro Percentual Absoluto Médio e Índice de Theil. Como resultado, o estudo comprovou que o método de Holt-Winters obteve o melhor resultado.

3.2 DESIGN DE PESQUISA

A definição do projeto de pesquisa é baseada no framework proposto por Saunders et al. (2019). A proposta define vários aspectos derivados dos objetivos da pesquisa: propósito, estratégia, método, técnicas de coleta de dados e procedimentos de análise de dados.

- I. Propósito: O propósito da pesquisa pode ser referido como explicativo porque o desenvolvimento da solução é baseado em relações previamente estabelecidas entre as variáveis (ou seja, o problema e sua causa raiz; PENG e MATSUI, 2016; SAUNDERS et al., 2019).
- II. Estratégia: Um estudo de caso é visto como uma estratégia apropriada para alcançar o propósito da pesquisa. Significa que a pesquisa está focada em uma investigação empírica de um fenômeno específico (ou seja, um processo de negócios) dentro de seu contexto de vida real (ou seja, o contexto organizacional) usando múltiplas fontes de evidência (SAUNDERS et al., 2019).
- III. Método: É a seleção de procedimentos sistemáticos para a descrição e a explicação de fenômenos. Esses procedimentos, que podem ser quantitativos ou qualitativos, se assemelham ao método científico que consiste em delimitar um problema, realizar observações e interpretá-las com base nas relações encontradas, fundamentando-se nas teorias existentes.

3.3 PREVISÃO DE DEMANDA

Previsões de demanda são elaboradas utilizando métodos quantitativos, qualitativos ou combinações de ambos e auxiliam nas tomadas de decisões relacionadas a cadeia de suprimentos.

Os métodos quantitativos baseiam-se na análise de séries temporais (coleção de observações feitas sequencialmente ao longo do tempo). Métodos qualitativos baseiam-se em opiniões de especialistas e por isso são mais sensíveis a vieses que podem impactar na confiabilidade dos resultados e decisões.

Os métodos qualitativos têm sido, historicamente, os mais utilizados na previsão da demanda (MENTZER & COX, 1984). Tais métodos apresentam um baixo grau de precisão em comparação aos métodos quantitativos; apesar disto, continuam sendo amplamente utilizados nas empresas, mesmo com a difusão dos métodos preditivos quantitativos mais avançados, impulsionada pelo avanço na capacidade de processamento e armazenamento de dados computacionais (SANDERS & MANRODT, 1994).

A extensa utilização dos métodos qualitativos parece estar relacionada ao fato das previsões por eles geradas corresponderem às metas de demanda estabelecidas pelas empresas (DIAS, 1999).

De acordo com Hanke (2001), os métodos de previsão de demanda envolvem estender os comportamentos do passado para o futuro. Supõe-se que as condições que geraram os resultados do passado não terão grandes variações que impactarão nos resultados futuros. A previsão não pode ser mais precisa do que os dados em que se baseia. Existem quatro principais critérios que podem ser aplicados para determinar se os dados serão úteis (HANKE, 2001):

- I. Os dados devem ser confiáveis e precisos. Medidas adequadas devem ser tomadas para garantir que os dados sejam coletados de fontes confiáveis, e atenção especial deve ser dada à precisão;
- II. Os dados devem ser relevantes de acordo com as circunstâncias em que estão sendo utilizados;
- III. Os dados devem ser consistentes;
- IV. O horizonte de tempo analisado deve ser adequado. Não se pode ter poucos dados ou muitos dados (dados de períodos históricos irrelevantes no passado).

As séries de demandas no segmento de comércio e varejo pertencem a um tipo especial de série temporal que geralmente possuem padrões de tendência e sazonalidade e com isso aumentando a complexidade em modelar as previsões com eficiência.

3.4 SÉRIES TEMPORAIS

Segundo Wanke e Julianelli (2006), uma série temporal se baseia em dados coletados, armazenados ou observados em incrementos de tempo sucessivos. Por isso, na pesquisa de tecnologia de previsão de receita operacional líquida, é possível definir o histórico de vendas de um determinado item ao longo do tempo.

De acordo com Tubino (2007), a previsão de demanda de uma série temporal se baseia no princípio de que a demanda futura será uma projeção de demandas passadas, independente de outras variáveis. Os métodos estatísticos para prever séries temporais tentam determinar os padrões de comportamento nas séries e usá-los para prever o valor futuro.

Estudos quantitativos com séries temporais se aplicam nas situações em que há um padrão persistente ou sistemático no comportamento da variável, que é possível de captar através de uma representação paramétrica (PINDYCK e RUBENFIELD, 1991). Entre os modelos preditivos mais utilizados destacam-se os de suavizamento exponencial, de média móvel, modelos Box & Jenkins, modelos Estruturais, modelos Bayesianos e de Redes Neurais.

3.5 METODOLOGIAS DE PREVISÃO

Segundo Hyndman (2009), as empresas usam métodos de previsão relativamente simples que muitas vezes não são baseados em modelagem estatística. Sobre o desenvolvimento de sistemas de previsão o autor coloca:

Uma organização precisa desenvolver um sistema de previsão que envolva várias abordagens para prever eventos incertos. Esses sistemas de previsão exigem o desenvolvimento de experiência na identificação de problemas de previsão, aplicação de uma variedade de métodos de previsão, seleção de métodos apropriados para cada problema e avaliação e refinamento de métodos de previsão ao longo do tempo. Também é importante ter forte suporte organizacional para o uso de métodos formais de previsão, a fim de que sejam usados com sucesso. (HYNDMAN, 2009).

3.5.1 Regressão linear simples

“O modelo de regressão linear simples analisa a relação entre duas variáveis de natureza quantitativa x e y , cuja tendência é aproximadamente representada por uma linha reta” (PESTANA; GAGEIRO, 2000, p. 447).

O principal foco do uso da regressão simples linear é estimar a função de regressão populacional com base na função de regressão amostral (GUJARATI, 2006). A função de regressão populacional de duas variáveis pode ser expressa por (ANDERSON et al, 2003; GUJARATI, 2006; STOCK; WATSON, 2004):

$$Y = a + bx + \epsilon \quad (1)$$

Onde:

Y é a variável dependente

x é a variável independente

a é o intercepto da reta de regressão da população

b é a declividade da reta de regressão da população

ϵ é o termo de erro; mede a variabilidade em Y que não pode ser explicada pela relação linear entre x e Y

Os valores de a e b são estimados através do método dos mínimos quadrados em que se estima os parâmetros, de modo a minimizar a soma dos quadrados dos erros.

Em decorrência da simplicidade desse modelo, ele não é amplamente utilizado para realizar previsões de demanda visto que as empresas são influenciadas por diversas variáveis que podem impactar na demanda e exigem modelos mais complexos para obter uma previsão com erro aceitável.

3.5.2 Regressão linear múltipla

Regressão múltipla é uma coleção de técnicas estatísticas para construir modelos que descrevem de maneira razoável relações entre várias variáveis explicativas de um determinado processo (Montgomery, Peck, & Vining, 2012). A diferença entre a regressão linear simples e a múltipla é que na múltipla são tratadas duas ou mais variáveis explicativas. O modelo pode ser expresso por (LEVINE et al., 2005):

$$Y = B_0 + b_1X_1 + b_2X_2 + \dots + b_kX_k + e \quad (2)$$

3.5.3 Média móvel centrada

Esse método geralmente é utilizado quando a série temporal apresenta sazonalidade, ou seja, variações que ocorrem para cima ou para baixo em intervalos regulares, existindo uma razão para a ocorrência e repetições das variações. Ele consiste em obter o índice de sazonalidade, que é o valor aplicado sobre a média ou a tendência que se desvia dos valores médios da série expressa em quantidade ou porcentagem (TUBINO, 2007).

O cálculo da média móvel centrada é obtido através da equação 3

$$MMC_t = \frac{(D_t + D_{t-1} + D_{t-2} + \dots + D_{t-n+1})}{n} \quad (3)$$

onde D_t são as demandas do ciclo sazonal e 'n' é o número de períodos considerados na média móvel.

Segundo Tubino (2007), o índice de sazonalidade é obtido através da equação 4.

$$IS_t = \frac{D_t}{MMC_t} \quad (4)$$

onde D_t é a demanda no período e MMC_t é a média móvel centrada neste período.

3.5.4 Suavização exponencial

Os modelos de suavização exponencial costumam ser comumente utilizados para previsão de demanda devido a sua simplicidade, facilidade de ajustes e boa acurácia. Esses modelos usam uma ponderação distinta para cada valor observado na série temporal, de modo que valores mais recentes recebam pesos maiores e tenham maior prioridade no cálculo. Assim, os pesos formam um conjunto que decai exponencialmente a partir de valores mais recentes (HYNDMAN et al., 2008).

Caso a série temporal se mantenha constante sobre um nível médio, uma suavização exponencial simples pode ser usada para definir valores futuros. Sua representação matemática vem dada por (Makridakis et al., 1998):

$$\hat{z}_{t+1} = \alpha z_t + (1 - \alpha)\hat{z}_t, \quad (5)$$

onde \hat{Z}_{t+1} é a previsão da demanda para o tempo $t+1$, feita no período atual t ; α é a constante de suavização, assumindo valores entre 0 e 1; Z_t é o valor observado na série temporal para o tempo t ; e, \hat{Z}_t é o valor da previsão feita para o tempo t .

Os modelos de suavização exponencial simples requerem uma estimativa inicial para \hat{Z}_t . Quando dados históricos estão disponíveis, pode-se usar uma média simples das N observações mais recentes como \hat{Z}_t ; caso contrário, pode-se utilizar a última observação, ou fazer uma estimativa subjetiva.

3.5.5 Método Holt-Winters

O modelo exponencial é um dos métodos de previsão mais conhecidos, pois permite alterações da sazonalidade ao longo do tempo (LAWTON, 1998). Em diversas empresas, as médias móveis são geralmente usadas para fazer previsões. O método Holt-Winters também usa uma média móvel, mas converte de simples para exponencial com o objetivo de representar melhor a tendência e sazonalidade dos dados. Assim, muitas vezes apresenta resultados mais assertivos do que com médias móveis simples.

Segundo Lawton (1998), os modelos exponenciais podem ser divididos em dois grupos: aditivo e multiplicativo. No modelo aditivo, a amplitude da variação sazonal é constante. No modelo multiplicativo, a amplitude da variação sazonal varia com o tempo.

Para realizar os cálculos do método, se utiliza de três equações alisadoras: uma para o nível, outra para tendência e outra para sazonalidade, que estão descritas da seguinte maneira no instante t : (HYNDMAN et al., 2008)

$$\text{Nível} = L_t = \alpha(Y_t - S_{t-s}) + (1 - \alpha)(L_{t-1} + b_{t-1}) \quad (6)$$

$$\text{Tendência} = b_t = \beta(L_t - L_{t-1}) + (1 - \beta)b_{t-1} \quad (7)$$

$$\text{Sazonalidade} = S_t = \gamma(Y_t - L_t) + (1 - \gamma)S_{t-s} \quad (8)$$

$$\text{Previsão} = F_{t+m} = L_t + b_{t-m} + S_{t-s+m} \quad (9)$$

Estimando as constantes de suavização (α , β , γ), sua interpretação se dá em uma espécie de peso atribuído a observação mais recente, ou seja, esta estimativa fica mais próxima de 1 quando seu padrão de comportamento se modifica com relativa frequência e mais próxima de 0 quando se mantém relativamente estável ao longo da amostra (SAMOHYL et al., 2008).

3.5.6 Box-Jenkins (ARIMA)

O modelo Autorregressivo Integrado de Média Móvel – Autoregressive Integrated Moving Average (ARIMA) é um método comum entre os modelos estatísticos de análise de séries temporais (LEE; KO, 2011). Esse modelo foi proposto por Box e Jenkins na década de 1970 e tem origem nos modelos autorregressivo (AR), médias móveis (MA) e da combinação dos modelos AR e MA (ARMA). Além de incluir modelos não estacionários (ARIMA) e sazonais (SARIMA).

De acordo com Bacci (2007), os modelos quantitativos ARIMA podem descrever duas classes de processos: Processos lineares estacionários e Processos lineares não estacionários homogêneos. Os Processos lineares estacionários utilizam basicamente três tipos de modelos, Processo auto regressivo de ordem p (AR (p)); Processo de médias móveis de ordem q (MA(q)) e Processo auto regressivo e de médias móveis de ordem p e q (ARMA (p, q)). Já os Processos lineares não estacionários homogêneos supõem que as séries não são estacionárias em nível e/ou inclinação (MORETTIN e TOLOI, 1987).

A aplicação correta do método depende se a série temporal é estacionária ou não. Uma série é estacionária quando não há tendência e sazonalidade nos dados, os dados flutuam em torno de uma média independentemente do tempo, e a variância permanece constante com o tempo.

O método para determinar se uma série é estacionária consiste em analisar os coeficientes de autocorrelação (ACF) e autocorrelação parcial (PACF). O coeficiente de autocorrelação (r_k) representa a correlação da série temporal com ela mesma (LEMOS, 2006), conforme a equação (10):

$$r_k = \frac{\sum_{t=k+1}^n (Y_t - \underline{Y}) - (Y_{t-k} - \underline{Y})}{\sum_{t=1}^n (Y_t - \underline{Y})^2} \quad (10)$$

O coeficiente de autocorrelação parcial de ordem k (a_k) pode ser calculado fazendo a regressão da variável Y_t com as observações da mesma variável de períodos anteriores. Os coeficientes de autocorrelação parcial (a_k) são as estimativas dos coeficientes b_k da regressão múltipla, conforme a equação (11):

$$Y_t = b_0 + b_1 Y_{t-1} + b_2 Y_{t-2} + \dots + b_k Y_{t-k} \quad (11)$$

onde b_k são os coeficientes da regressão múltipla e os demais termos conforme definição apresentada na equação (1).

O modelo ARIMA exige que a série seja estacionária, ou seja, sem tendência ou sazonalidade. Para transformar uma série em estacionária, é aplicada uma técnica de diferenciação, gerando uma série com $n-1$ valores, onde cada valor é obtido conforme a equação (12):

$$Y_t = Y_t - Y_{t-1} \quad (12)$$

No modelo ARIMA, a variável de interesse é expressa por um agregado de valor anteriores e um ruído aleatório na parte autorregressiva (AR). Na parte da média móvel (MA) é explorada a estrutura de autocorrelação dos resíduos de previsão do período atual com aqueles ocorridos em períodos anteriores. Por fim, a parte integrada (I) indica que os valores de dados foram substituídos com a diferença entre seus valores e os valores anteriores e este processo diferenciador pode ter sido realizado mais de uma vez. O propósito de cada uma destas características é fazer o modelo se ajustar aos dados da melhor forma possível.

Muitas séries temporais apresentam padrões repetitivos que aparecem regularmente a cada intervalo de tempo. Como é o caso das indústrias, em que vendas e produção seguem uma sazonalidade forte em determinados períodos do ano.

Para lidar com as séries que apresentam autocorrelação sazonal, Box e Jenkins (1976) generalizaram o modelo ARIMA e definiram o modelo ARIMA sazonal multiplicativo, conhecido como SARIMA (p,d,q) (P,D,Q)m em que p é a ordem (número de defasagens) do modelo auto-regressivo, d é o grau de diferenciação (o número de vezes em que os dados tiveram valores passados subtraídos), q é a ordem do modelo de média móvel, m se refere ao

número de períodos que define a sazonalidade e P, D e Q se referem aos termos de auto-regressão, diferenciação e média móvel para a parte sazonal do modelo SARIMA.

3.6 MEDIDAS DE ERRO DE PREVISÃO

Segundo Samohyl et al. (2008), a identificação e investigação de discrepâncias frequentemente estão associadas a melhores resultados de previsão. Segundo os mesmos autores, define-se discrepâncias como a diferença entre os valores observados e os previstos.

Visto que o presente estudo busca apresentar e comparar o desempenho de diferentes técnicas de previsão, nas próximas subseções serão expostas algumas das medidas de erro utilizadas no desenvolvimento deste trabalho.

3.6.1 Erro absoluto médio (MAE)

Segundo Willmott e Matsuura (2015), o erro absoluto médio é uma métrica de avaliação de modelo usada com modelos de regressão. O erro absoluto médio de um modelo em relação a um conjunto de teste é a média dos valores absolutos dos erros de predição individuais em todas as instâncias do conjunto de teste. Cada erro de previsão é a diferença entre o valor verdadeiro e o valor previsto para a instância. O erro absoluto médio pode ser representado pela equação:

$$MAE = \frac{1}{n} \sum_{n=1}^n |P_t - O_t| \quad (13)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

3.6.2 Erro percentual médio (MPE)

Quando é necessário verificar se um método de previsão está retornando uma previsão muito alta ou muito baixa, utiliza-se esse método, assim é possível verificar se existe viés de

alta ou baixa na previsão. Se a média encontrada está próxima de zero então não existe viés, se for uma porcentagem negativa, a previsão está errando para baixo, se for positivo então a previsão está errando para cima. O MPE é calculado pela seguinte expressão:

$$MPE = \frac{1}{n} \sum_{t=1}^n \frac{P_t - O_t}{O_t} \quad (14)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

3.6.3 Erro percentual absoluto médio (MAPE)

O erro percentual absoluto médio (MAPE) é calculado usando o erro absoluto em cada período dividido pelos valores observados no período. Então, calculando a média dessas porcentagens fixas. Esta abordagem é útil quando o tamanho ou tamanho de uma variável de predição é significativo na avaliação da precisão de uma previsão. O MAPE indica quanto erro de previsão em comparação com o valor real (SAMOHYL et al., 2008). Pode ser representado pela equação:

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{P_t - O_t}{O_t} \right| \quad (15)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

3.6.4 U de theil

O U de Theil consiste em uma medida relativa de erro uma vez em que compara os erros da previsão obtida com os erros provenientes de uma previsão de um passo atrás. (SAMOHYL et al. 2008). Representa-se através da equação:

$$U = \sqrt{\frac{\sum_{t=1}^{n-1} \left[\left(\frac{\hat{Y}_{t+1} - Y_t}{Y_t} \right) - \left(\frac{Y_{t+1} - Y_t}{Y_t} \right) \right]^2}{\sum_{t=1}^{n-1} \left(\frac{Y_{t+1} - Y_t}{Y_t} \right)^2}} \quad (16)$$

Onde:

Y = Observado

\hat{Y} = Previsto

Segundo Samohyl et al. (2008), trata-se o U de Theil de uma importante medida de erro a medida em que pode auxiliar em decisões sobre investimento de esforços para obtenção de previsões.

Deste modo, à medida que o U de Theil aproxima-se de um (1,00) interpreta-se proximidade da previsão com aquela obtida pelo método ingênuo, uma vez que o valor projetado é igual ao último ocorrido ($\hat{Y}_{t+1} = Y_t$). Da mesma forma em que a proximidade do zero, por sua vez, indica similaridade com a previsão perfeita ($\hat{Y}_{t+1} = Y_{t+1}$).

3.6.5 Raiz do erro quadrático médio (RMSE)

A raiz do erro quadrático médio (RMSE em Inglês), é comumente usada para expressar a acurácia dos resultados numéricos com a vantagem de que RMSE apresenta valores do erro nas mesmas dimensões da variável analisada. O RMSE é definido por:

$$RMSE = \sqrt{\frac{1}{n} \sum_{n=1}^n (P_t - O_t)^2} \quad (17)$$

Onde:

n = Número de observações;

P_t = Previsto no período t ;

O_t = Observado no período t .

4 PROCEDIMENTOS METODOLÓGICOS

Esta seção está dividida em duas partes, a primeira trata de como este trabalho se enquadra nos conceitos de pesquisa, sendo ele classificado conforme os critérios característicos da metodologia científica. Em seguida, o roteiro metodológico é apresentado com uma breve descrição de cada etapa que compõe o estudo.

4.1 CLASSIFICAÇÃO DA PESQUISA

O presente trabalho metodologicamente é classificado como um estudo quantitativo. Segundo Cohen (1980) os estudos quantitativos são definidos como pesquisas que aplicam métodos empíricos e declarações empíricas. Ele afirma que uma declaração empírica é definida como uma declaração descritiva sobre o que "é" o caso no "mundo real" ao invés do que "deveria" ser o caso. Normalmente, as afirmações empíricas são expressas em termos numéricos. Outro fator na pesquisa quantitativa é que as avaliações empíricas são aplicadas. Avaliações empíricas são definidas como uma forma que busca determinar o grau em que um programa ou política específica cumpre empiricamente ou não um determinado padrão ou norma.

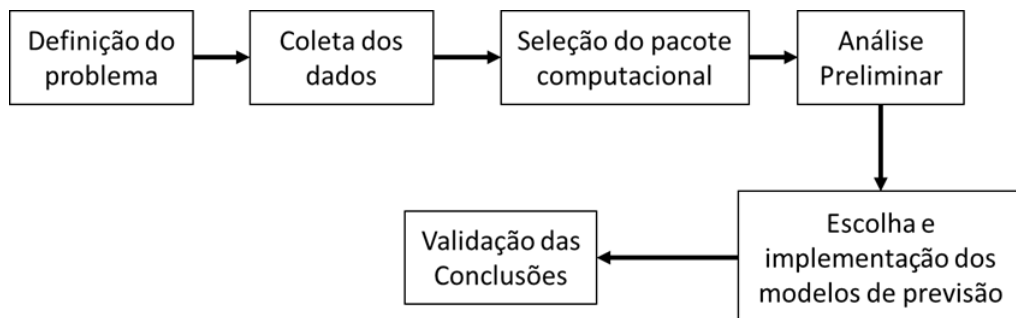
Além disso, Creswell (1994) define estudo quantitativo como um tipo de pesquisa que explica fenômenos por meio da coleta de dados numéricos que são analisados usando métodos baseados em matemática (em particular estatísticos).

Os procedimentos técnicos usados se classificam como modelagem e simulação, pois compreende o uso de modelos, por meio de técnicas quantitativas para descrever o comportamento de um sistema ou de parte dele (BERTO; NAKANO, 2000). A coleta de dados foi feita com dados secundários, coletados do banco de dados do *software* Economatica®. Os resultados da pesquisa têm objetivo aplicado, visto que se busca um modelo que possa ser utilizado na prática para prever projeções futuras de receita e auxiliar na tomada de decisão dos gestores.

4.2 CARACTERIZAÇÃO DO MÉTODO DE TRABALHO

As etapas para a implementação do sistema de previsão de demanda envolveram a metodologia de previsão de Lemos (2006), que foi ampliada através da adição do quarto passo chamado de Análise Preliminar. As etapas podem ser observadas a seguir através da Figura 1.

Figura 1 — Etapas do método de trabalho



Fonte: Elaborado pelo autor (2021).

A primeira etapa foi a definição do problema a ser auxiliado pelas previsões. Nessa etapa, procurou-se definir quais dados seriam utilizados e quais empresas seriam abordadas. Além disso, foi definido também variáveis importantes, tais como o horizonte de previsão com o intuito de direcionar a coleta de informações na etapa seguinte.

A segunda etapa envolveu a obtenção de informações relevantes a serem utilizadas. Os dados escolhidos a serem coletados na etapa anterior foram os valores das receitas líquidas operacionais das principais empresas do subsetor de comércio listadas na B3. Mesmo que cada empresa tenha feito sua abertura de capital em momentos distintos, o horizonte de tempo dos dados utilizados foi de 2010 em diante, com o ajuste da inflação e com a frequência dos períodos sendo trimestral. A principal motivação dessa escolha é que por mais que valores antigos das séries temporais não tenham tanta influência em comparação a valores dos períodos mais recentes quando se realiza projeções futuras, o subsetor de comércio sofreu grande impacto com a crise de 2008 e isso impactaria na amostra analisada para modelar as projeções. Por serem empresas de capital aberto, os dados foram coletados através do banco de dados disponibilizado no *software* Economatica®.

Após selecionados os dados, a terceira etapa da implementação consistiu na seleção de um pacote computacional para a previsão. No momento da escolha do *software*, foram levadas em consideração as necessidades do processo de previsão, seu custo e manutenção demandada. O pacote computacional foi então escolhido considerando análises de suas

limitações quanto ao número e tipo de previsão, sua flexibilidade quanto a variações e volume de dados de entrada, ajustes subjetivos, capacidade e métodos de previsão disponíveis. Nesse estudo em específico foi utilizado o *software* R e seus pacotes para os métodos de previsão e representação gráfica dos dados.

A próxima etapa contemplou o primeiro passo na construção das análises, onde as séries temporais foram agrupadas e representadas graficamente. Desta maneira, pode-se analisar e identificar a presença, ou não, de valores atípicos. Além disso, foram analisados graficamente a presença, ou não, de tendência, sazonalidade e também estacionaridade para possível aplicação do modelo ARIMA. Vale ressaltar que as análises gráficas são apenas visualização do comportamento dos dados e que em conjunto também foi feito análises quantitativas para verificação de tendência, sazonalidade, estacionaridade e entre outras características. Esta análise forneceu subsídios que auxiliaram na escolha do modelo quantitativo utilizado na modelagem matemática da série temporal.

A quinta etapa constituiu a escolha e implementação dos métodos quantitativos utilizados no estudo. Como as análises de séries temporais utilizam o histórico dos dados anteriores para elaborar a previsão, assumem que os padrões dos dados passados irão se repetir no futuro. Nessa etapa serão aplicados diferentes métodos de previsão com os dados de cada empresa para que na etapa seguinte seja feita avaliação das medidas de acuracidade e seja proposto qual o melhor método em cada caso.

Por fim, a validação do método proposto foi feita com o intuito de assegurar sua funcionalidade. Sua avaliação foi realizada pela medida da acurácia de sua previsão, através de três diferentes testes de acuracidade sendo eles Erro Absoluto Médio (MAE), Erro Percentual Absoluto Médio (MAPE) e Raiz do Erro Quadrático Médio (RMSE). O objetivo foi avaliar sua eficiência e potencial para utilizações futuras. Na validação dos métodos, compararam-se previsões de demanda com valores realizados nos períodos do passado. O melhor método é considerado validado quando ao utilizar diferentes métricas de erro, o melhor resultado apresentado é o que minimiza a diferença entre os valores previstos e os valores observados. Ou seja, quanto mais próximo de zero for essa diferença, melhor é o modelo de previsão.

De acordo com Peng e Matsui (2016), a etapa final de uma análise de dados é a maneira com que os resultados são apresentados, ou seja, o quão claro estão as conclusões de forma direta e visual para a audiência. No presente estudo, os resultados devem ser apresentados de maneira fácil e clara, a fim de mostrar a execução dos objetivos propostos e o desempenho de acurácia dos modelos.

5 DESENVOLVIMENTO


O presente capítulo trata da aplicação do método de trabalho proposto no capítulo anterior em quatro diferentes empresas de capital aberto do subsegmento de comércio usando como base os dados de receita operacional líquida disponibilizados em relatórios trimestrais.

5.1 DEFINIÇÃO DO PROBLEMA

Os passos propostos na seção anterior foram aplicados em um caso prático, em 4 empresas do segmento de comércio de capital aberto sendo elas a Magazine Luiza S.A , Americanas S.A , Via Varejo S.A e Lojas Renner S.A. São duas principais motivações pela escolha dessas empresas para o presente estudo. Primeiramente essas empresas possuem similaridade no aspecto de gama de produtos comercializados e canais de vendas utilizados e também por serem as maiores empresas nesse segmento. Além disso, a pandemia do COVID-19 modificou o comportamento dos consumidores, principalmente pelo aumento da demanda no e-commerce. Sendo assim, muitas empresas, principalmente as de comércio e varejo, tiveram as receitas impactadas e com isso os dados mais recentes de receita operacional líquida tiveram comportamento significativamente diferente em comparação ao histórico das séries temporais. Por esse fator, o presente estudo deu um peso maior para os períodos mais recentes ao realizar as projeções futuras, que também teve um foco no curto prazo ao prever os próximos 24 meses, visto que neste período prevê-se que as empresas ainda estarão sob o impacto da pandemia, sendo, portanto, realizados dois cenários possíveis para as previsões: com regressão gradual da pandemia ou seu contínuo.

Os dados da Pesquisa Mensal de Comércio (PMC) do IBGE nos últimos 20 anos indicam um período de ascensão das vendas no setor até 2014, seguido por dois anos de resultados negativos. De 2017 em diante, o segmento apresentou leve recuperação, chegando ao final de 2019 a um nível semelhante ao do segundo trimestre de 2015. (Figura 2).

Figura 2 — Volume de vendas no comércio varejista do Brasil




Fonte: IBGE (2021b); Elaborado pelo autor.

No entanto, a chegada da pandemia rompeu com essa tendência, afetando duramente o setor. Se em dezembro de 2019 o índice de volume de vendas do comércio varejista atingira 97,1, ele caiu para 95,2 em março e para 79,5 em abril.

Os meses de maio a novembro apresentaram altas consecutivas. Em julho de 2020, o índice de volume de vendas indicava a retomada do patamar prévio à pandemia (97,6, em comparação a 97,7 em fevereiro). Já em novembro, o índice atingiu o maior patamar histórico, em 102,8.

Um estudo realizado em abril de 2021 pela empresa SmartHint mostrou que no ano de 2020 houve um aumento no faturamento em e-commerce de 41% em relação ao ano anterior, como pode ser observado na Figura 3.

Figura 3 — Histórico do faturamento no e-commerce brasileiro.




Fonte: SmartHint (2021).

Além disso, o mesmo estudo mostrou que houve um aumento de 29% do número de consumidores no e-commerce em 2020 em comparação ao ano anterior. Tomando como referência o resultado da Magazine Luiza S.A em 2020, por ser uma das maiores empresas no segmento, o e-commerce representou cerca de 70% de todas as vendas. A título de comparação, quando a empresa abriu seu capital em 2011 a representação do e-commerce era de 10% (SEU DINHEIRO, 2021).

Figura 4 — Participação do e-commerce nas vendas do Magazine Luiza S.A nos últimos trimestres

E-commerce em alta

Desde o segundo trimestre de 2020, o e-commerce representa mais de 60% das vendas totais do Magazine Luiza



Fonte: SeuDinheiro (2021).

O presente estudo busca trazer de forma analítica o impacto que a pandemia trouxe para setor de comércio das empresas de capital aberto e também analisar de forma comparativa diferentes modelos estatísticos de previsão de suas receitas líquidas levando esse impacto em consideração. Vale ressaltar que as projeções foram feitas após a divulgação dos resultados do primeiro trimestre de 2021, considerando o contexto daquele momento. Ou seja, como a data do fim da pandemia ainda é incerta e com novas variantes da COVID-19 surgindo, as previsões foram feitas levando em consideração de que a pandemia continuaria e que o e-commerce continuaria aquecido.

5.2 COLETA DOS DADOS

A coleta das informações iniciou-se pela compilação de todo o histórico de receita operacional líquida não consolidada disponibilizado pelas empresas através do *software* Economática®. A receita operacional líquida trata-se do valor da venda de produtos e mercadorias ou da prestação de serviços durante um determinado período contábil menos devoluções, descontos e impostos incidentes sobre vendas. Sendo assim, a principal motivação para o uso desse indicador financeiro como base é que ele permitiria analisar de fato as receitas do negócio, visto que a alternativa de uso das receitas brutas poderiam mascarar as efetivas receitas de vendas que ficam para a empresa para cobrir seus gastos correntes, custos e despesas e como alguns fatores externos, como a pandemia do COVID 19, as afetariam.

No que se refere ao espaço amostral, o conjunto de dados da receita líquida de cada empresa possui 45 períodos trimestrais ajustados pela inflação que se inicia desde 2010 até os últimos resultados trimestrais publicados, com exceção da Magazine Luiza S.A que abriu seu capital no início de 2011 e da Via Varejo S.A que foi coletado de 2013 em diante por questões de fusões que fortemente alteraram os valores. Para a projeção das receitas futuras foi escolhido o período de 24 meses. Vale destacar que dados anteriores a 2010 não foram levados em consideração por se tratar de períodos muito distantes, que não refletem a realidade atual das empresas e que não iriam interferir nas projeções de curto prazo, o qual é o foco deste trabalho.

5.3 SELEÇÃO DO PACOTE COMPUTACIONAL

Na análise das séries temporais da demanda foi utilizado o *software* R por se tratar de um software amplamente utilizado para análises estatísticas. Esse *software* possui uma série de


pacotes com modelos de previsão, ferramentas estatísticas e geração de gráficos das análises de dados.

5.4 ANÁLISE PRELIMINAR

Para iniciar a aplicação dos modelos de previsão, uma análise gráfica preliminar foi realizada com o objetivo de identificar o padrão das receitas, além de erros de registro, lacunas e outliers, que podem ter sido causados por algum problema no banco de dados do Economatica®. Vale destacar que qualquer período anormal de receita, seja de alta ou de baixa, foi mantido mesmo sendo um outlier.

Os dados históricos das empresas foram levantados e apresentados nos gráficos abaixo. A Figura 5 representa o comportamento do histórico de receita da empresa Magazine Luiza. Nela é possível notar que as receitas tiveram uma tendência crescente e também sazonalidade com picos no último trimestre de cada ano. Essa característica é comum no setor de comércio, visto que no fim do ano ocorre mais vendas em decorrência do Black Friday e do Natal. Por fim, vale destacar o impacto que a pandemia do COVID-19 trouxe à empresa com o recorde de faturamento no ano de 2020.


Figura 5 — Receita Operacional Líquida - Magazine Luiza S.A



Fonte: Elaborado pelo Autor (2021).

A série temporal da empresa varejista Via Varejo S.A apresentou um comportamento diferente no que se refere à tendência com uma leve queda mas com a sazonalidade constante nos últimos trimestres de cada ano.


Figura 6 — Receita Operacional Líquida - Via Varejo S.A



Fonte: Elaborado pelo Autor (2021).

Em relação ao histórico de receita da Lojas Americanas S.A é possível notar o impacto que a crise no Brasil entre 2014 e 2018 trouxe à empresa e também a retomada com a pandemia no final de 2020.


Figura 7 — Receita Operacional Líquida - Americanas S.A



Fonte: Elaborado pelo Autor (2021).

O histórico de receita das Lojas Renner apresenta um crescimento e constância da sazonalidade bastante visível. Também vale destacar o impacto que a pandemia trouxe no início de 2020 com um dos piores resultados desde a abertura de capital, mas que em seguida conseguiu retomar as vendas no final do ano.

Figura 8 — Receita Operacional Líquida - Lojas Renner S.A



Fonte: Elaborado pelo Autor (2021).

De maneira geral não foram encontrados valores espúrios nas séries; porém verificou-se a ocorrência de padrões cíclicos de variação, que se repetem em intervalos relativamente

constantes de tempo, indicando sazonalidade nas receitas com picos acentuados na última observação de cada ciclo sazonal e tendência de crescimento ao longo do tempo.

5.5 ESCOLHA E IMPLEMENTAÇÃO DOS MODELOS DE PREVISÃO

A partir da análise visual dos dados, foi escolhido diferentes modelos de previsão, sendo eles o de Suavização Exponencial de Holt-Winters, Média Móvel Centrada e o método ARIMA com sazonalidade (também conhecido como SARIMA). Esses modelos se justificam por descrever adequadamente séries temporais formadas por dados que apresentam tendência linear e sazonalidade, simultaneamente (Makridakis et al, 1998). Além disso, também permitem serem configurados para projeções de curto prazo ou longo prazo.

5.5.1 Aplicação dos modelos estatísticos


Antes da aplicação dos modelos de previsão foi feita a decomposição das séries temporais, que consiste em um modelo univariado que usa formulações simples para decompor a série em três componentes principais, a partir dos quais, são feitas as previsões: (a) a tendência, que se refere à direção geral que os dados se desenvolvem em um longo intervalo de tempo; (b) a sazonalidade, que se refere à presença de variações que ocorrem em intervalos regulares específicos; e (c) o termo aleatório, que aparece com flutuações de curto período, com deslocamento inexplicável (MAKRIDAKIS e WHEELWRIGHT, 1982; R. SOUZA, 1989).

Em seguida, os modelos estatísticos Holt-Winters, Média Móvel Centrada e SARIMA foram aplicados utilizando o software R e seus pacotes de previsão e análise de acuracidade. A grande vantagem do uso do software é que ele permite utilizar pacotes que facilitam na modelagem, como por exemplo no SARIMA em que é analisado todas as possíveis atribuições ao $(p,d,q)(P,D,Q)$ e seleciona o melhor modelo com base nos critérios AIC e BIC. Os resultados de cada modelo de previsão assim como a análise de acuracidade serão demonstrados nos próximos subcapítulos de forma individual para cada empresa.

5.5.1.1 *Magazine luiza S.A*

A Figura 9 demonstra a decomposição da série temporal dos dados referente à Magazine Luiza S.A.

Figura 9 — Decomposição da receita operacional líquida da Magazine Luiza S.A




Fonte: Elaborado pelo autor (2021).

A decomposição evidencia a forte tendência crescente a partir do ano de 2016. A componente de sazonalidade identificada demonstra como nos últimos trimestres de cada ano ocorre o pico, uma característica comum no subsetor de comércio.

Em seguida foi aplicado o modelo de Média Móvel Centrada com o ajuste de sazonalidade. O ajuste de sazonalidade pode ser feito usando o índice sazonal multiplicativo ou aditivo. O utilizado foi o multiplicativo por apresentar os menores erros de previsão. Esse comportamento foi observado em todas as empresas. Isso pode ser explicado pelo fato de que as vendas online foram crescendo com os anos e também alavancado pela pandemia e como o índice aditivo não projeta um crescimento crescente no percorrer do tempo, o índice multiplicativo se adequa melhor. A Figura 10 representa a forma gráfica do modelo, assim como a previsão de receita em 12 e 24 meses.

Figura 10 — Previsão da receita operacional líquida (em mil R\$) para Magazine Luiza S.A por Média Móvel Centrada



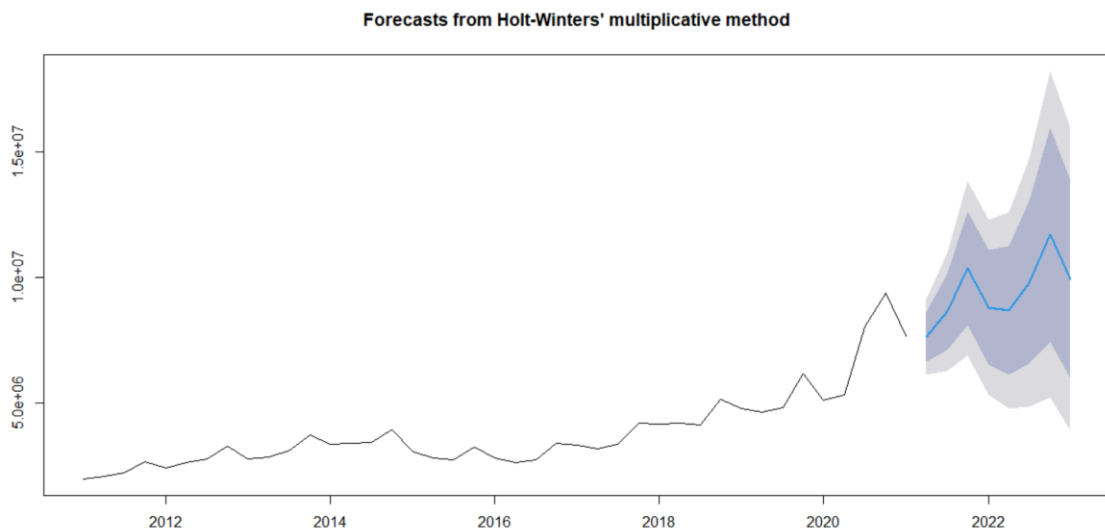
Fonte: Elaborado pelo autor (2021).

É possível destacar como o modelo acompanhou de forma eficiente os valores de receita passados e projetou os próximos períodos seguindo a tendência crescente.

Ao utilizar o método de Holt-Winters foi analisado o tipo da componente de sazonalidade e o parâmetro de suavização definido como α (Alpha). Esse parâmetro possui uma faixa de valores entre 0 e 1, sendo que o mais próximo de 1 significa que os últimos períodos da série temporal terão peso maior ao projetar os futuros períodos. Como esse estudo foca em analisar o impacto da pandemia nas receitas líquidas das empresas, o valor definido para todas as empresas foi de 0,9 por estar próximo de 1.

A Figura 11 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores. Note que nos primeiros 12 meses, essas faixas de confiança estão mais próximas da previsão do que nos 24 meses de previsão. Essa ampliação do distanciamento com a linha da previsão é por causa da maior imprevisibilidade dos períodos mais distantes no futuro. Assim, o modelo busca criar faixas que absorvem essa imprevisibilidade mas por outro lado ter uma amplitude muito grande de previsão não auxilia na tomada de decisão. Por isso optou-se nesse estudo em não modelar previsões acima de 24 meses, devido à forte instabilidade do período atual de pandemia e aumento das incertezas e das faixas de confiança. Os valores exatos previstos e as faixas de confiança de todos os modelos se encontram nos apêndices.


Figura 11 — Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Magazine Luiza S.A



Fonte: Elaborado pelo autor (2021).

Para encontrar os parâmetros $(p, d, q)(P, D, Q)m$ que definem o modelo SARIMA, foi utilizado uma biblioteca específica no R que permite auxiliar o analista de dados ao fornecer os parâmetros ótimos para a série temporal de acordo com o menor AIC (*Akaike information criterion*), critério que avalia modelos estatísticos de acordo com o erro e complexidade do modelo. Os parâmetros selecionados para o modelo SARIMA de acordo com a seleção do software foram $(3,1,0)(1,0,0)_4$. Isso significa que na parte sem sazonalidade houve 3 defasagens (3ª ordem), com aplicação de 1 diferenciação na série para gerar estacionariedade na série. E na parte com sazonalidade houve 1 defasagem (1ª ordem). A Figura 12 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.


Figura 12 — Previsão SARIMA da receita operacional líquida (em mil R\$) para Magazine Luiza S.A



Fonte: Elaborado pelo autor (2021).

Para melhor visualização dos resultados, os gráficos com as previsões de cada modelo e a série original foram compilados na Figura 13.

Figura 13 — Comparação entre os modelos preditivos (em mil R\$) para Magazine Luiza S.A



Fonte: Elaborado pelo autor (2021).

Os três modelos projetam uma tendência crescente mas o modelo SARIMA merece destaque por projetar valores bastante otimistas para os períodos futuros. O modelo de média móvel centrada é o único que projeta um recuo na receita seguido de períodos de alta.

Após a implementação dos modelos preditivos foi calculado os erros MAPE, RMSE e MAE de cada modelo. A tabela 3 representa o teste de acuracidade da Magazine Luiza S.A.

Tabela 3 — Teste de Acuracidade da Magazine Luiza S.A

Magazine Luiza S.A	MAE	RMSE	MAPE
Média Móvel Centrada	228370,3	491684,4	4,2%
Holt-Winters	249946,7	417422,4	6,1%
SARIMA	254905,0	409342,0	6,3%


Fonte: Elaborado pelo autor (2021).

O modelo da média móvel centrada obteve melhor resultado no cálculo do MAE e do MAPE, com exceção do cálculo da RMSE (raiz do erro quadrático médio) em que o SARIMA obteve melhor desempenho.

5.5.1.2 Via varejo S.A

A decomposição da série temporal referente aos resultados da Via Varejo S.A , mostrada na Figura 14 demonstra um aumento das receitas no ano de 2013 e alta sazonalidade em todos os períodos analisados. Os termos aleatórios não foram tão discrepantes em relação à série.


Figura 14 — Decomposição da receita operacional líquida da Via Varejo S.A



Fonte: Elaborado pelo autor (2021).

Da mesma maneira, inicialmente foi aplicado o modelo de Média Móvel Centrada com o ajuste de sazonalidade. O índice sazonal utilizado foi o multiplicativo por apresentar os menores erros de previsão. A Figura 15 representa a forma gráfica do modelo, assim como a previsão de receitas em 12 e 24 meses.

Figura 15 — Previsão da receita operacional líquida (em mil R\$) para Via Varejo S.A por Média Móvel Centrada

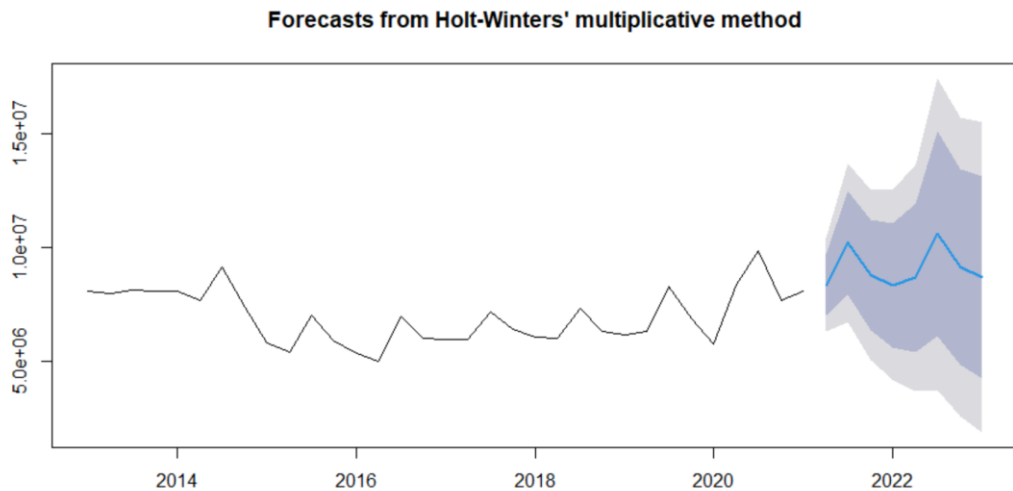


Fonte: Elaborado pelo autor (2021).

A partir do gráfico é possível notar que o modelo acompanhou a tendência mas teve diversos períodos de inversão entre os picos de alta e baixa, o que prejudicaria as projeções das receitas.

Ao utilizar o método de Holt-Winters, o valor definido para o parâmetro de suavização também foi de 0,9 por estar o mais próximo de 1. A Figura 16 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.


Figura 16 — Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Via Varejo S.A



Fonte: Elaborado pelo autor (2021).

Na aplicação do modelo SARIMA os parâmetros $(p, d, q)(P, D, Q)m$ foram definidos pelo R e resultaram nos valores de $(0,1,0)(0,1,1)_4$. Logo, na parte sem sazonalidade houve uma diferenciação da série para obtenção da estacionariedade e na parte com sazonalidade houve uma diferenciação da série e um dado pode ser explicado pelo erro de um valor anterior. A Figura 17 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.


Figura 17 — Previsão SARIMA da receita operacional líquida (em mil R\$) para Via Varejo S.A



Fonte: Elaborado pelo autor (2021).

Para melhor visualização dos resultados, os gráficos com as previsões de cada modelo e a série original foram compilados na Figura 18.

Figura 18 — Comparação entre os modelos preditivos (em mil R\$) para Via Varejo S.A



Fonte: Elaborado pelo autor (2021).

É possível observar que os modelos Holt-Winters e SARIMA tiveram comportamento semelhante mas com o SARIMA projetando receitas um pouco superiores, enquanto a média móvel centrada gerou pico sazonal a mais que não foi previsto pelos outros. Além disso, a média móvel centrada projetou valores mais otimistas em comparação aos outros. Após a implementação dos modelos preditivos foi calculado os erros MAPE, RMSE e MAE de cada modelo. A tabela 4 representa o teste de acuracidade da Via Varejo S.A.

Tabela 4 — Teste de Acuracidade da Via Varejo S.A

Via Varejo S.A	MAE	RMSE	MAPE
Média Móvel Centrada	437228,8	673456,6	8,9%
Holt-Winters	488881,0	706125.6	6,9%
SARIMA	475183.1	737735.9	6,7%


Fonte: Elaborado pelo autor (2021).

O modelo de média móvel centrada obteve melhor desempenho em dois testes, enquanto o modelo SARIMA obteve melhor desempenho no resultado do MAPE. Vale ressaltar que esse modelo gerou previsões bastante otimistas e também houve o erro de inversão dos picos na comparação aos valores de receita líquida passados já citado anteriormente. Então cabe ao analista de dados levar isso em consideração ao optar pelo melhor modelo com os dados desta empresa, além da observação do cenário macroeconômico atual e seu impacto no negócio.

5.5.1.3 Americanas S.A

Em relação à decomposição dos dados da Americanas S.A, a tendência se demonstra pouco relevante, mas com uma característica crescente nos últimos períodos. O componente da sazonalidade também se faz bem presente na série.


Figura 19 — Decomposição da receita operacional líquida da Americanas S.A



Fonte: Elaborado pelo autor (2021).

Assim como nos casos anteriores, inicialmente foi aplicado o modelo de Média Móvel Centrada com o ajuste de sazonalidade. O índice sazonal utilizado foi o multiplicativo por apresentar os menores erros de previsão. A Figura 20 representa a forma gráfica do modelo, assim como a previsão de receitas em 12 e 24 meses.

Figura 20 — Previsão da receita operacional líquida (em mil R\$) para Americanas S.A por Média Móvel Centrada

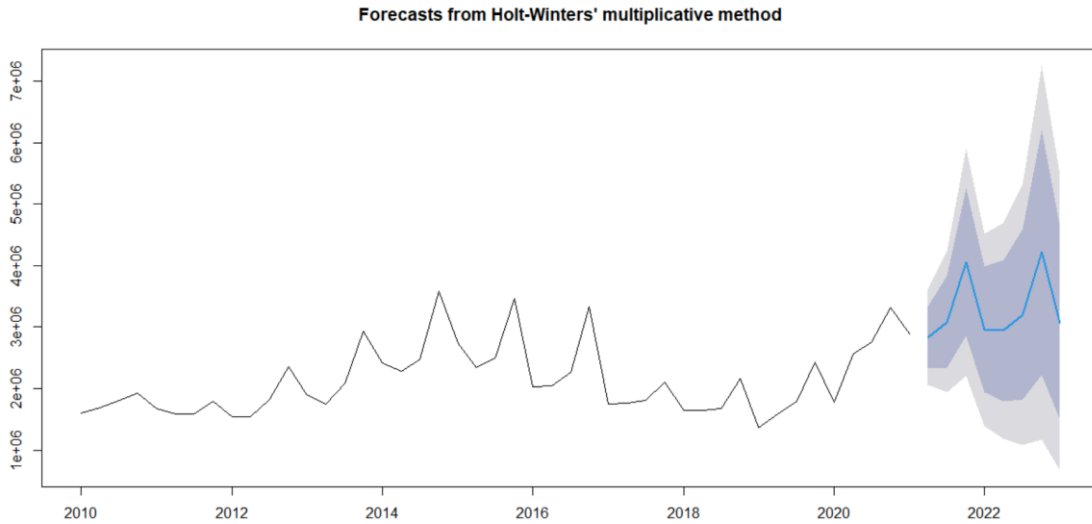


Fonte: Elaborado pelo autor (2021).

Nesse caso o modelo acompanhou de forma eficiente os valores de receitas passadas e projetou os próximos períodos seguindo a tendência crescente e com aumento do pico para os próximos 24 meses. Na aplicação do método de Holt-Winters, o valor definido para o parâmetro de suavização também foi de 0,9 por estar o mais próximo de 1. A Figura 21 representa a

previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.

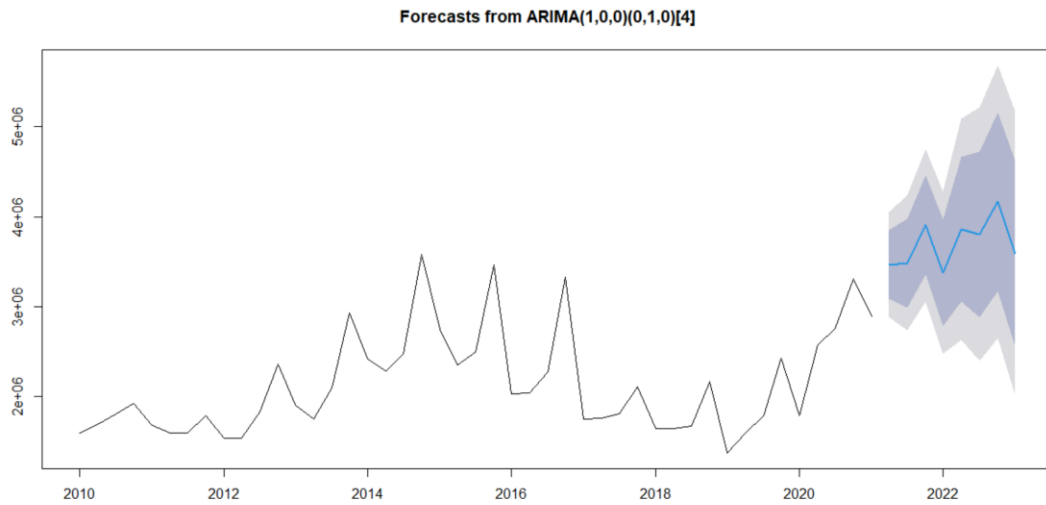
Figura 21 — Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Americanas S.A



Fonte: Elaborado pelo autor (2021).

Na aplicação do modelo SARIMA os parâmetros $(p, d, q)(P, D, Q)m$ foram definidos pelo R e resultaram nos valores de $(1,0,0)(0,1,0)_4$. Logo, na parte sem sazonalidade houve uma defasagem (1ª ordem) da série e sem nenhuma necessidade de diferenciação para obtenção da estacionariedade, apenas com uso dos dados contemporâneos - termo usado para os dados do momento e na parte com sazonalidade houve 1 diferenciação na série para estacionarizá-la. A Figura 22 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.

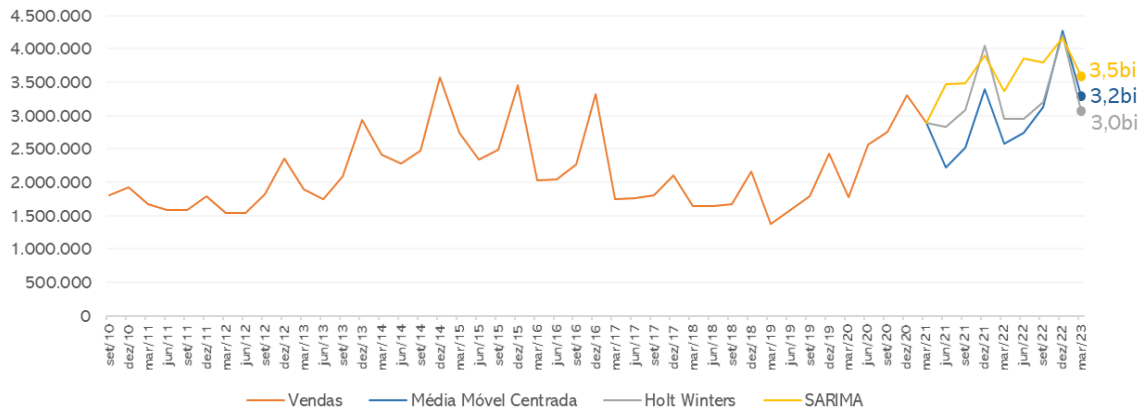
Figura 22 — Previsão SARIMA da receita operacional líquida (em mil R\$) para Americanas S.A



Fonte: Elaborado pelo autor (2021).

Para melhor visualização dos resultados, os gráficos com as previsões de cada modelo e a série original foram compilados na Figura 23.

Figura 23 — Comparação entre os modelos preditivos (em mil R\$) para Americanas S.A



Fonte: Elaborado pelo autor (2021).

Com o gráfico é possível notar que a Média Móvel Centrada focou mais nas sazonalidades advindas de períodos passados, com fortes altas e baixas consecutivas na previsão. Porém o SARIMA focou mais no trimestre anterior (pois houve apenas 1 defasagem) perfazendo maior previsão de volume de receita, e oscilações sazonais menos expressivas, oriundo da forte expansão do e-commerce do período da pandemia.

Após a implementação dos modelos preditivos foi calculado os erros MAPE, RMSE e MAE de cada modelo. A tabela 5 representa o teste de acuracidade da Americanas S.A.

Tabela 5 — Teste de Acuracidade da Americanas S.A

Americanas S.A	MAE	RMSE	MAPE
Média Móvel Centrada	144525,9	206141,6	6,3%
Holt-Winters	191043,7	257309,0	9,0%
SARIMA	191201,5	281043,5	9,2%


Fonte: Elaborado pelo autor (2021).

A média móvel centrada teve o melhor desempenho em todos os testes de acuracidade. Então nesse caso, é o modelo mais recomendado para as projeções. Com o gráfico também é possível observar que foi o único modelo que projetou um período de queda seguido de alta nas receitas.

5.5.1.4 Lojas renner S.A

Por fim, a Figura 24 representa a decomposição da série dos resultados das Lojas Renner S.A. A tendência crescente em todos os períodos foi fortemente impactada com o efeito da pandemia, sendo esta dentre as demais a que mais sofreu com o início da pandemia, mas que vem se recuperando fortemente nos últimos períodos. Os termos aleatórios também tiveram maior impacto com o efeito da pandemia.


Figura 24 — Decomposição da receita operacional líquida da Lojas Renner S.A



Fonte: Elaborado pelo autor (2021).

Na sequência, foi aplicado o modelo de Média Móvel Centrada com o ajuste de sazonalidade nos dados das Lojas Renner S.A. O índice sazonal utilizado foi o multiplicativo por apresentar os menores erros de previsão. A Figura 25 representa a forma gráfica do modelo, assim como a previsão de receitas em 12 e 24 meses.

Figura 25 — Previsão da receita operacional líquida (em mil R\$) para Lojas Renner S.A por Média Móvel Centrada




Fonte: Elaborado pelo autor (2021).

É possível destacar como o modelo acompanhou com boa acuracidade a tendência e sazonalidade dos dados passados e projetou receitas com tendência mais suavizada do que os valores dos períodos anteriores, compatível já com a queda menos expressiva do último período e consequente tendência de amenização das fortes oscilações para os períodos futuros projetados pela Média Móvel Centrada.

Na implementação do método de Holt-Winters, o valor definido para o parâmetro de suavização foi de 0,9. A Figura 26 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.


Figura 26 — Previsão Holt-Winters da receita operacional líquida (em mil R\$) para Lojas Renner S.A



Fonte: Elaborado pelo autor (2021).

No modelo SARIMA os parâmetros $(p, d, q)(P, D, Q)m$ foram definidos pelo R e resultaram nos valores de $(0,1,2)(0,1,0)_4$. Ou seja, na parte sem sazonalidade os dados atuais, sem defasagem, foram priorizados, com uso de uma diferenciação para sua estacionariedade e ainda explicados pelos erros dos seus dois valores anteriores e na parte com sazonalidade houve 1 diferenciação na série para sua estacionariedade, priorizando também os valores atuais para a predição das sazonalidades e sem uso de valores defasados dos erros. A Figura 27 representa a previsão dos próximos 24 meses e também a previsão nas faixas de confiança de 80% e 95% dos valores.


Figura 27 — Previsão SARIMA da receita operacional líquida (em mil R\$) para Lojas Renner S.A



Fonte: Elaborado pelo autor (2021).

Na Figura 28 é possível observar a comparação entre os modelos. O único modelo que teve um comportamento diferente dos demais foi o SARIMA que gerou sazonalidade com grande amplitude entre os valores das receitas. O Holt-Winters e a Média Móvel Centrada mantiveram padrões bem igualitários com projeções mais amenizadas e voltando aos padrões anteriores à pandemia - situação típica de uma amenização da pandemia, enquanto o SARIMA priorizou a manutenção dos acontecimentos dos picos da pandemia com fortes oscilações.

Figura 28 — Comparação entre os modelos preditivos (em mil R\$) para Lojas Renner S.A



Fonte: Elaborado pelo autor (2021).

Após a implementação dos modelos preditivos foi calculado os erros MAPE, RMSE e MAE de cada modelo. A tabela 6 representa o teste de acuracidade da Lojas Renner S.A.

Tabela 6 — Teste de Acuracidade da Lojas Renner S.A

Lojas Renner S.A	MAE	RMSE	MAPE
Média Móvel Centrada	97015,5	185074,3	8,7%
Holt-Winters	140953,4	267370,7	12,6%
SARIMA	105816,0	254226,5	10,9%

Fonte: Elaborado pelo autor (2021).


O modelo de média móvel centrada obteve o melhor desempenho em todos os testes realizados. Os outros modelos tiveram desempenho semelhante nos testes, mas ainda muito abaixo do modelo escolhido. Vale destacar que mesmo o modelo SARIMA realizando projeções bem discrepantes dos outros modelos, ainda não foi o de pior desempenho de acuracidade.

5.6 VALIDAÇÃO DAS CONCLUSÕES

Após realizar todas as análises de acuracidade dos modelos nas séries das empresas foi possível concluir que o modelo Média Móvel Centrada teve o melhor desempenho na grande maioria das análises, seguido pelo SARIMA para as empresas Magazine Luiza e Via Varejo. Frente à grande imprevisibilidade do momento atual, com constantes notícias de vacinas, novas cepas, constantes reaberturas e fechamentos de comércios físicos, a melhor situação é o próprio analista escolher qual o melhor modelo dentre os dois apontados pelos resultados de acuracidade. Os gráficos também demonstraram que esse modelo acompanhou bem os períodos anteriores. Vale destacar o desempenho do modelo com a série da Magazine Luiza S.A que resultou em um erro de apenas 4,2%.

Outro fator que deve ser levado em consideração é em relação ao cenário econômico que o setor de comércio se encontra e quais as expectativas sobre ele nos próximos períodos. Economistas afirmam que apesar do avanço da vacinação contra o coronavírus e da reabertura gradual da economia, a recuperação da atividade econômica tem sido leve nos últimos meses em meio à escalada da inflação, recuperação tímida do mercado de trabalho, aumento das incertezas fiscais e políticas e também do avanço recente da nova cepa indiana, Delta, do coronavírus (IBGE, 2021). A Figura 29 demonstra o impacto da economia no setor de comércio.

Figura 29 — Vendas do comércio nos últimos 12 meses.



Fonte: Economia/G1 (2021).

Esse fator externo impacta na escolha de alguns ajustes nos modelos preditivos. O modelo de suavização exponencial de Holt-Winters permite configurar o parâmetro de amortecimento dos futuros períodos. Ou seja, em projeções para médio prazo, acima de dois anos nos quais há cenários em que o setor de comércio não tenha alta expectativa de recuperação é possível ajustar esse parâmetro ϕ , representado por Φ , que varia na faixa de 0 e 1, sendo 1 com alto amortecimento e 0 com baixo, para que os valores previstos se ajustem mais com a realidade de médio ou longo prazos. Devido à grande instabilidade econômica e social no qual o mundo está inserido, assim como a economia nacional, esta pesquisa focou no curto prazo, a fim de obter dados com mais acuracidade de receita para os próximos trimestres. Essa tomada de decisão levando em consideração os fatores externos e, conseqüentemente a projeção de variados cenários possíveis, é bastante importante e estratégica e o analista de dados precisa estar ciente desse impacto ao modelar as projeções. No estudo presente, não foi considerado o parâmetro de amortecimento por se tratar de projeções para o curto prazo, assim como para realização de comparações com a mesma referência em todos os modelos sem nenhum ajuste de fatores externos para os próximos períodos.

6 CONCLUSÕES E RECOMENDAÇÕES

Diante de um cenário cada vez mais competitivo, as previsões de demanda são essenciais nas tomadas de decisão das organizações, servindo como direcionamento em diversos setores internos. No setor de comércio especificamente, pela variação de comportamento dos consumidores, sazonalidade, novas tendências de produtos e outros fatores, ter boa acurácia nas previsões de demanda resulta na redução de diversos custos, assim como custos de estoque, custo de oportunidade em vendas perdidas, custo de estocagem entre outros.

Em 2020 com o impacto da pandemia do COVID-19 o setor de comércio sofreu um enorme impacto com o fechamento das lojas físicas e mudança no comportamento dos consumidores que fortaleceu o e-commerce como nunca antes visto. As empresas que estavam bem posicionadas no digital e conseguiram prever com eficiência o volume de vendas conseguiram enxergar a crise como oportunidade e se destacar na concorrência.

O presente trabalho teve como objetivo realizar um estudo quantitativo comparando diferentes modelos de previsão da demanda através das projeções das receitas líquidas das principais empresas listadas na B3 do subsetor do comércio sendo elas a Magazine Luiza S.A, Via Varejo S.A, Americanas S.A e Lojas Renner S.A levando em consideração o impacto que a pandemia trouxe nas vendas nos períodos mais recentes. Ou seja, prevendo um cenário de amenização da pandemia com a vacinação mas não sua total erradicação, prevendo-se que nos próximos dois anos o e-commerce ainda estaria fortalecido frente à continuidade das medidas de prevenções básicas, como distanciamento social e higiene.

A etapa de coleta dos dados foi feita através dos resultados divulgados nos balanços trimestrais nos últimos 10 anos. Dados históricos da receita operacional líquida serviram de base para a aplicação de diferentes modelos preditivos a análise comparativa de acuracidade entre eles. Os modelos preditivos escolhidos foram o média móvel centrada, Holt-Winters e Arima com sazonalidade (SARIMA).

Os resultados obtidos permitem afirmar que o modelo da média móvel centrada obteve melhor desempenho na grande maioria dos testes de acuracidade nas empresas. Os únicos teste em que teve um resultado diferente foi cálculo da raiz do erro quadrático médio nos dados da Magazine Luiza S.A em que o modelo SARIMA obteve melhor acurácia e no erro absoluto percentual médio nos dados da Via Varejo S.A em que também o SARIMA foi melhor. Dos resultados conclui-se que cabe ao analista escolher entre os dois modelos de melhor acuracidade: o modelo média móvel seguido pelo SARIMA, com base nas métricas avaliadas,

MAE, MAPE e RMSE, considerando o prazo de dois anos de projeção e a impactante mudança das receitas líquidas de vendas dos últimos períodos.

Para trabalhos futuros, recomenda-se avaliar o uso de outros métodos de previsão, em especial os de redes neurais, ou outro adicional além dos abordados que seja recomendado na questão de previsão em séries temporais. Além disso, testar o método Holt-Winters com amortecimento nos períodos de médio e longo prazos futuros para avaliar o quanto o ajuste qualitativo pode ser importante para se ajustar no modelo e realizar previsões mais assertivas para períodos longínquos os quais incorrem em maiores possibilidades de erros preditivos. Outro foco de estudo interessante seria realizar as previsões analisando estatística espacial em diferentes regiões do Brasil. Por fim, recomenda-se investigação das séries a partir de recortes temporais alternativos ao utilizado neste estudo (trimestral) entre os quais: semanal, quinzenal ou mensal.

REFERÊNCIAS

AGUIAR, Victor. Vendas do Magazine Luiza saltam 62% no trimestre; e-commerce é 70% do total. *seudinheiro*, 13 mai. 2021. Empresas. Disponível em: <https://www.seudinheiro.com/2021/empresas/magazine-luiza-e-commerce-balanco-1t21/>. Acesso em: 29 jul. 2021.

ANDERSON, David R. et al. *Estatística aplicada à administração e economia*. São Paulo: Pioneira Thomson Learning, 2003

Arunraj, NS and D Ahrens (2015). A hybrid seasonal autoregressive integrated moving average and quantile regression for daily food sales forecasting. *International Journal*.

AQUINO, E. M.; SILVEIRA, I. H.; PESCARINI, J. M., AQUINO, R.; SOUZAFILHO, J. A. D. Medidas de distanciamento social no controle da pandemia de COVID19: potenciais impactos e desafios no Brasil. In: *Ciência & Saúde Coletiva*, v. 25, p. 2423-2446. 2020.

BACCI, L. A. *Combinação de métodos de séries temporais para a previsão da demanda de café no Brasil*. Tese de mestrado UNIFEI, 2007.

BERTO, R. M. V. S.; NAKANO, D. N. A. *Produção Científica nos Anais do Encontro Nacional de Engenharia de Produção: Um Levantamento de Métodos e Tipos de Pesquisa*. *Produção*, v. 9, n. 2, p. 65-76, 2000.

BOWERSOX, D. J.; CLOSS, D. J. *Logística Empresarial, O Processo de Integração da Cadeia de Suprimento*. São Paulo, Editora Atlas, 2009.

BOX, G. E. P.; JENKINS, G. M. *Time series analysis forecasting and control*. San Francisco: H. Day, 1976.

CABRAL, Umberlândia. Vendas do comércio caem 1,7% em junho após dois meses de alta. Agência de notícias IBGE. 11 ago. 2021. *Estatísticas Econômicas*. Disponível em: <https://agenciadenoticias.ibge.gov.br/agencia-noticias/2012-agencia-de-noticias/noticias/31354-vendas-no-varejo-caem-1-7-em-junho-apos-dois-meses-de-alta>.

Choi, T.-M., Yu, Y., Au, K.-F., 2011. A hybrid SARIMA wavelet transform method for sales forecasting. *Decis. Support Syst.* 51 (1), 130–140.

Cohen, L.; Manion, L., *Research Methods in Education*, London: Groom Helm Ltd., 1980.

Creswell, J.W., *Research Design: Qualitative & Quantitative Approaches*, London: SAGE Publications, 1994.

Da Veiga, C.P., Da Veiga, C.R.P., Catapan, A., Tortato, U. and Da Silva, W.V. (2014) Demand Forecasting in Food Retail: A Comparison between the Holt-Winters and ARIMA Models. *WSEAS Transactions on Business and Economics*, 11, 608-614.

DIAS, G. P. P. Proposta de processo de previsão de vendas para bens de consumo. Anais do XIX ENEGEP - CD-ROM, Rio de Janeiro, 1999.

GUJARATI, Damodar. *Econometria básica*. Rio de Janeiro: Elsevier, 2006.

HANKE, J.E.; REITSCH, A.G; WICHERN, D.W. *Business Forecasting*. 7 ed. 54 New Jersey: Prentice Hall, 2001.

HYNDMAN, R. J. et al. *Forecasting with Exponential Smoothing: The state space Approach*. New York: Springer, 2008.

HYNDMAN, R. J. *Business forecasting methods*. 2009 Disponível em: <<https://robjhyndman.com/papers/businessforecasting.pdf>>. Acesso em: 25 mai.2021.

IBGE – Instituto Brasileiro de Geografia e Estatística. *Pesquisa Mensal de Comércio – PAC*. Rio de Janeiro: IBGE. Disponível em: www.ibge.gov.br. Acesso em: 29 jul. 2021.

LAWTON, R. How should additive Holt–Winters estimates be corrected? *International Journal of Forecasting*. v. 14, p. 393–403, 1998.

LEE, Cheng-Min; KO, Chia-Nan. Short-term load forecasting using lifting scheme and ARIMA models. *Expert Systems with Applications*, v. 38, p. 5902-5911, 2011.

LEVINE, D.M; BERENSON, M.L.; STEPHAN, D. *Estatística: Teoria e Aplicações*. Rio de Janeiro: LTC, 2005.

LEMOES, F. O. *Metodologia para Seleção de Método de Previsão de Demanda*. Porto Alegre: UFRGS, 2006. 183 f. Dissertação (Mestrado em Engenharia de Produção) - Programa de Pós-Graduação em Engenharia de Produção, Departamento de Engenharia de Produção e Transportes, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2006.

Makridakis, S., & Wheelwright, S. (1982). *The handbook of forecasting: a manager's guide*. New York: John Wiley & Sons, Inc.

MAKRIDAKIS, S., WHEELWRIGHT, S. C. & HYNDMAN, R. J. (1998). *Forecasting – methods and applications*, 3ª ed., John Wiley, New York.

MAYER, Raymond R. *Administração da Produção*. São Paulo: Atlas, 1990.

MENTZER, J. T & COX fr., J. E. Family lity, application, and performance of sales forecasting techniques. *Journal of Forecasting*, v. 3, 11. 1, p. 27-37, jan. 1997.

MONTGOMERY, D.C.; PECK, E. A.; VINING, G. G. Introduction to Linear Regression Analysis. 5. ed. [s.l.] John Wiley & Sons, 2012.

MORETTIN, P. A; TOLOI, C. M. C. Previsão de séries temporais. 2. ed. São Paulo: Atual editora, 1987.

OECD – Organisation for Economic Co-operation and Development. OECD Economic Survey of Brazil. France: OECD, 2020.

PENG, R. D.; MATSUI, E. The Art of Data Science: A Guide for Anyone Who Works with Data. Lulu.com, p. 155, 2016.

PESTANA, Maria Helena; GAGEIRO, João Nunes. Análise de dados para ciências sociais – a complementaridade do SPSS. Lisboa: Silabo, 2000.

PINDYCK, R. S.; RUBENFIELD, D. L. Econometric Models and Economic Forecasts. New York, McGrawHill, 3rd Ed., 1991. 565p.

RICHARDSON, R. J. Pesquisa social: métodos e técnicas. São Paulo: Atlas, 1985.

SAMOHYL, Robert Wayne; SOUZA, Gueibi Peres; DE MIRANDA, Rodrigo Gabriel. Métodos simplificados de previsão empresarial. Ciência Moderna, 2008.

SANDERS, N. R. & MANRODT. K. B. Forecasting practices in US corporations: survey results. Interfaces, v. 24, n. 2, p. 92- 101, mar. 1994.

SAUNDERS, M., Lewis, P., & Thornhill, A. (2019). Research methods for business students (3rd ed.) Pearson Education Limited.

SILVA, A. F.. Definição de um modelo de previsão das vendas da rede varejista Alfabeto. 2008. Tese de Doutorado. UNIVERSIDADE FEDERAL DE JUIZ DE FORA. Disponível em: < http://www.ufjf.br/ep/files/2014/07/2008_3_Andr%C3%A9.pdf> Acesso em: 11 de dez. 2018.

Souza, R. (1989, julho). Modelos estruturais para previsão de séries temporais: abordagens clássica e bayesiana. Anais do Colóquio Brasileiro de Matemática, Rio de Janeiro, RJ, Brasil, 17.

STOCK, James H.; WATSON, Mark W. Econometria. São Paulo: Addison Wesley, 2004.

TEIXEIRA, Luciana. Modelo de Previsão de Faturamento Diário de uma Empresa de Varejo Luciana. 2014. Trabalho de conclusão de curso (Especialização em Estatística – Ênfase em Indústria e Mercado) - UNIVERSIDADE FEDERAL DE MINAS GERAIS, UNIVERSIDADE FEDERAL DE MINAS GERAIS, 2014.

TUBINO, D. F. Planejamento e controle da produção. São Paulo: Atlas, 2007. 190 p.

WANKE, P. JULIANELLI, L., 2006, Previsão de Vendas. 1 ed., São Paulo: Atlas.

Willmott, C. and Matsuura, K.: Advantages of the Mean Absolute Error (MAE) over the Root Mean Square Error (RMSE) in assessing average model performance, *Clim. Res.*, 30, 79–82, 2005

Yin R. Estudo de caso: planejamento e métodos. 2a ed. Porto Alegre: Bookman; 2001.

APÊNDICE A – MODELOS ARIMA ANALISADOS E BEST MODEL - MAGAZINE
LUIZA S.A

ARIMA(0,1,0)		: 1194.28
ARIMA(0,1,0)	with drift	: 1194.892
ARIMA(0,1,0)(0,0,1)[4]		: 1179.081
ARIMA(0,1,0)(0,0,1)[4]	with drift	: 1179.927
ARIMA(0,1,0)(0,0,2)[4]		: 1173.236
ARIMA(0,1,0)(0,0,2)[4]	with drift	: 1174.377
ARIMA(0,1,0)(1,0,0)[4]		: Inf
ARIMA(0,1,0)(1,0,0)[4]	with drift	: Inf
ARIMA(0,1,0)(1,0,1)[4]		: Inf
ARIMA(0,1,0)(1,0,1)[4]	with drift	: Inf
ARIMA(0,1,0)(1,0,2)[4]		: 1173.116
ARIMA(0,1,0)(1,0,2)[4]	with drift	: 1174.821
ARIMA(0,1,0)(2,0,0)[4]		: Inf
ARIMA(0,1,0)(2,0,0)[4]	with drift	: Inf
ARIMA(0,1,0)(2,0,1)[4]		: Inf
ARIMA(0,1,0)(2,0,1)[4]	with drift	: Inf
ARIMA(0,1,0)(2,0,2)[4]		: Inf
ARIMA(0,1,0)(2,0,2)[4]	with drift	: 1177.359
ARIMA(0,1,1)		: 1196.332
ARIMA(0,1,1)	with drift	: 1195.421
ARIMA(0,1,1)(0,0,1)[4]		: 1179.485
ARIMA(0,1,1)(0,0,1)[4]	with drift	: 1181.318
ARIMA(0,1,1)(0,0,2)[4]		: 1173.48
ARIMA(0,1,1)(0,0,2)[4]	with drift	: 1175.433
ARIMA(0,1,1)(1,0,0)[4]		: Inf
ARIMA(0,1,1)(1,0,0)[4]	with drift	: Inf
ARIMA(0,1,1)(1,0,1)[4]		: 1170.699
ARIMA(0,1,1)(1,0,1)[4]	with drift	: 1172.94
ARIMA(0,1,1)(1,0,2)[4]		: 1173.224
ARIMA(0,1,1)(1,0,2)[4]	with drift	: 1175.545
ARIMA(0,1,1)(2,0,0)[4]		: 1171.874
ARIMA(0,1,1)(2,0,0)[4]	with drift	: 1174.09
ARIMA(0,1,1)(2,0,1)[4]		: Inf
ARIMA(0,1,1)(2,0,1)[4]	with drift	: Inf
ARIMA(0,1,1)(2,0,2)[4]		: Inf
ARIMA(0,1,1)(2,0,2)[4]	with drift	: 1178.43
ARIMA(0,1,2)		: 1194.979
ARIMA(0,1,2)	with drift	: 1193.374
ARIMA(0,1,2)(0,0,1)[4]		: 1178.686
ARIMA(0,1,2)(0,0,1)[4]	with drift	: 1178.475
ARIMA(0,1,2)(0,0,2)[4]		: 1171.581
ARIMA(0,1,2)(0,0,2)[4]	with drift	: 1172.046
ARIMA(0,1,2)(1,0,0)[4]		: Inf
ARIMA(0,1,2)(1,0,0)[4]	with drift	: Inf
ARIMA(0,1,2)(1,0,1)[4]		: Inf
ARIMA(0,1,2)(1,0,1)[4]	with drift	: 1170.122
ARIMA(0,1,2)(1,0,2)[4]		: Inf
ARIMA(0,1,2)(1,0,2)[4]	with drift	: 1173.261
ARIMA(0,1,2)(2,0,0)[4]		: 1169.356
ARIMA(0,1,2)(2,0,0)[4]	with drift	: 1170.984
ARIMA(0,1,2)(2,0,1)[4]		: 1171.264
ARIMA(0,1,2)(2,0,1)[4]	with drift	: 1173.059

ARIMA(0,1,3)		: Inf
ARIMA(0,1,3)	with drift	: Inf
ARIMA(0,1,3)(0,0,1)[4]		: 1176.978
ARIMA(0,1,3)(0,0,1)[4]	with drift	: 1176.258
ARIMA(0,1,3)(0,0,2)[4]		: 1173.977
ARIMA(0,1,3)(0,0,2)[4]	with drift	: 1174.218
ARIMA(0,1,3)(1,0,0)[4]		: Inf
ARIMA(0,1,3)(1,0,0)[4]	with drift	: 1171.656
ARIMA(0,1,3)(1,0,1)[4]		: Inf
ARIMA(0,1,3)(1,0,1)[4]	with drift	: 1172.936
ARIMA(0,1,3)(2,0,0)[4]		: 1172.082
ARIMA(0,1,3)(2,0,0)[4]	with drift	: 1173.883
ARIMA(1,1,0)		: 1196.47
ARIMA(1,1,0)	with drift	: 1196.932
ARIMA(1,1,0)(0,0,1)[4]		: 1181.07
ARIMA(1,1,0)(0,0,1)[4]	with drift	: 1182.329
ARIMA(1,1,0)(0,0,2)[4]		: 1175.246
ARIMA(1,1,0)(0,0,2)[4]	with drift	: 1176.788
ARIMA(1,1,0)(1,0,0)[4]		: Inf
ARIMA(1,1,0)(1,0,0)[4]	with drift	: Inf
ARIMA(1,1,0)(1,0,1)[4]		: Inf
ARIMA(1,1,0)(1,0,1)[4]	with drift	: Inf
ARIMA(1,1,0)(1,0,2)[4]		: 1174.984
ARIMA(1,1,0)(1,0,2)[4]	with drift	: 1177.1
ARIMA(1,1,0)(2,0,0)[4]		: 1173.306
ARIMA(1,1,0)(2,0,0)[4]	with drift	: Inf
ARIMA(1,1,0)(2,0,1)[4]		: Inf
ARIMA(1,1,0)(2,0,1)[4]	with drift	: Inf
ARIMA(1,1,0)(2,0,2)[4]		: Inf
ARIMA(1,1,0)(2,0,2)[4]	with drift	: 1179.91
ARIMA(1,1,1)		: 1197.792
ARIMA(1,1,1)	with drift	: 1196.491
ARIMA(1,1,1)(0,0,1)[4]		: 1180.93
ARIMA(1,1,1)(0,0,1)[4]	with drift	: 1182.576
ARIMA(1,1,1)(0,0,2)[4]		: 1174.022
ARIMA(1,1,1)(0,0,2)[4]	with drift	: 1175.806
ARIMA(1,1,1)(1,0,0)[4]		: 1169.566
ARIMA(1,1,1)(1,0,0)[4]	with drift	: Inf
ARIMA(1,1,1)(1,0,1)[4]		: 1169.904
ARIMA(1,1,1)(1,0,1)[4]	with drift	: 1172.209
ARIMA(1,1,1)(1,0,2)[4]		: 1172.679
ARIMA(1,1,1)(1,0,2)[4]	with drift	: 1175.083
ARIMA(1,1,1)(2,0,0)[4]		: 1170.846
ARIMA(1,1,1)(2,0,0)[4]	with drift	: Inf
ARIMA(1,1,1)(2,0,1)[4]		: Inf
ARIMA(1,1,1)(2,0,1)[4]	with drift	: Inf

ARIMA(1,1,2)		: 1197.417
ARIMA(1,1,2)	with drift	: 1195.967
ARIMA(1,1,2)(0,0,1)[4]		: 1180.835
ARIMA(1,1,2)(0,0,1)[4]	with drift	: 1180.468
ARIMA(1,1,2)(0,0,2)[4]		: 1174.218
ARIMA(1,1,2)(0,0,2)[4]	with drift	: 1174.584
ARIMA(1,1,2)(1,0,0)[4]		: 1169.849
ARIMA(1,1,2)(1,0,0)[4]	with drift	: 1171.666
ARIMA(1,1,2)(1,0,1)[4]		: 1171.31
ARIMA(1,1,2)(1,0,1)[4]	with drift	: Inf
ARIMA(1,1,2)(2,0,0)[4]		: 1172.09
ARIMA(1,1,2)(2,0,0)[4]	with drift	: Inf
ARIMA(1,1,3)		: Inf
ARIMA(1,1,3)	with drift	: Inf
ARIMA(1,1,3)(0,0,1)[4]		: Inf
ARIMA(1,1,3)(0,0,1)[4]	with drift	: Inf
ARIMA(1,1,3)(1,0,0)[4]		: 1172.619
ARIMA(1,1,3)(1,0,0)[4]	with drift	: 1174.56
ARIMA(2,1,0)		: 1190.253
ARIMA(2,1,0)	with drift	: 1187.32
ARIMA(2,1,0)(0,0,1)[4]		: 1175.967
ARIMA(2,1,0)(0,0,1)[4]	with drift	: 1174.921
ARIMA(2,1,0)(0,0,2)[4]		: 1171.337
ARIMA(2,1,0)(0,0,2)[4]	with drift	: 1171.401
ARIMA(2,1,0)(1,0,0)[4]		: 1167.967
ARIMA(2,1,0)(1,0,0)[4]	with drift	: 1168.976
ARIMA(2,1,0)(1,0,1)[4]		: 1169.869
ARIMA(2,1,0)(1,0,1)[4]	with drift	: 1170.918
ARIMA(2,1,0)(1,0,2)[4]		: 1172.098
ARIMA(2,1,0)(1,0,2)[4]	with drift	: 1174.053
ARIMA(2,1,0)(2,0,0)[4]		: 1170.353
ARIMA(2,1,0)(2,0,0)[4]	with drift	: 1171.433
ARIMA(2,1,0)(2,0,1)[4]		: 1172.577
ARIMA(2,1,0)(2,0,1)[4]	with drift	: 1173.833
ARIMA(2,1,1)		: 1192.724
ARIMA(2,1,1)	with drift	: 1189.704
ARIMA(2,1,1)(0,0,1)[4]		: 1178.262
ARIMA(2,1,1)(0,0,1)[4]	with drift	: 1177.579
ARIMA(2,1,1)(0,0,2)[4]		: 1172.92
ARIMA(2,1,1)(0,0,2)[4]	with drift	: 1173.387
ARIMA(2,1,1)(1,0,0)[4]		: Inf
ARIMA(2,1,1)(1,0,0)[4]	with drift	: Inf
ARIMA(2,1,1)(1,0,1)[4]		: Inf
ARIMA(2,1,1)(1,0,1)[4]	with drift	: 1172.57
ARIMA(2,1,1)(2,0,0)[4]		: 1171.603
ARIMA(2,1,1)(2,0,0)[4]	with drift	: 1173.18

```

ARIMA(2,1,2) : Inf
ARIMA(2,1,2) with drift : Inf
ARIMA(2,1,2)(0,0,1)[4] : Inf
ARIMA(2,1,2)(0,0,1)[4] with drift : 1174.797
ARIMA(2,1,2)(1,0,0)[4] : 1169.19
ARIMA(2,1,2)(1,0,0)[4] with drift : 1170.614
ARIMA(2,1,3) : Inf
ARIMA(2,1,3) with drift : Inf
ARIMA(3,1,0) : 1192.705
ARIMA(3,1,0) with drift : 1189.058
ARIMA(3,1,0)(0,0,1)[4] : 1177.532
ARIMA(3,1,0)(0,0,1)[4] with drift : 1177.346
ARIMA(3,1,0)(0,0,2)[4] : 1171.392
ARIMA(3,1,0)(0,0,2)[4] with drift : 1172.401
ARIMA(3,1,0)(1,0,0)[4] : 1167.111
ARIMA(3,1,0)(1,0,0)[4] with drift : 1168.941
ARIMA(3,1,0)(1,0,1)[4] : 1169.569
ARIMA(3,1,0)(1,0,1)[4] with drift : 1171.39
ARIMA(3,1,0)(2,0,0)[4] : Inf
ARIMA(3,1,0)(2,0,0)[4] with drift : 1171.713
ARIMA(3,1,1) : Inf
ARIMA(3,1,1) with drift : Inf
ARIMA(3,1,1)(0,0,1)[4] : 1179.275
ARIMA(3,1,1)(0,0,1)[4] with drift : 1179.764
ARIMA(3,1,1)(1,0,0)[4] : 1169.885
ARIMA(3,1,1)(1,0,0)[4] with drift : 1171.879
ARIMA(3,1,2) : Inf
ARIMA(3,1,2) with drift : Inf

```

Best model: ARIMA(3,1,0)(1,0,0)[4]

Series: vendasMGLU
ARIMA(3,1,0)(1,0,0)[4]

Coefficients:

	ar1	ar2	ar3	sar1
	0.2264	-0.4378	0.4955	0.8387
s.e.	0.1452	0.1295	0.2329	0.0862

sigma^2 estimated as 1.908e+11: log likelihood=-577.67
AIC=1165.35 AICc=1167.11 BIC=1173.79

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	8827502	8267663	9387341	7971302	9683702
2021 Q3	11780718	10894802	12666635	10425826	13135610
2021 Q4	12225010	11222047	13227974	10691110	13758911
2022 Q1	10839156	9647739	12030574	9017041	12661272
2022 Q2	12465667	10695413	14235920	9758297	15173036
2022 Q3	14732311	12549368	16915255	11393787	18070835
2022 Q4	14796388	12367956	17224820	11082422	18510354
2023 Q1	13975308	11192086	16758530	9718737	18231878

APÊNDICE B – MODELO HOLT-WINTERS - MAGAZINE LUIZA S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	7621507	6641439	8601575	6122622	9120392
2021 Q3	8620325	7088584	10152067	6277729	10962921
2021 Q4	10351168	8077107	12625230	6873291	13829045
2022 Q1	8801198	6529129	11073266	5326368	12276027
2022 Q2	8681677	6124595	11238759	4770957	12592396
2022 Q3	9779135	6556138	13002132	4849987	14708283
2022 Q4	11697409	7442736	15952083	5190447	18204371
2023 Q1	9909809	5972932	13846686	3888876	15930743

APÊNDICE C – MODELO MÉDIA MÓVEL CENTRADA - MAGAZINE LUIZA S.A

	Qtr1	Qtr2	Qtr3	Qtr4
2011			2195711	2695714
2012	2457447	2490985	2709115	3246029
2013	2867431	2838693	3074820	3741707
2014	3330034	3249260	3366322	3800712
2015	3116129	2821316	2817299	3221955
2016	2752927	2654865	2841898	3467167
2017	3134118	3167837	3490694	4329767
2018	3946764	3982614	4329184	5194563
2019	4614347	4620058	4967451	5934556
2020	5586136	6095354	7031442	7243861
2021	6501342	6483960	7015395	8510400
2022	7627971	7596838	8207259	9940821
2023	8895810			

**APÊNDICE D – MODELOS ARIMA ANALISADOS E BEST MODEL – VIA
VAREJO S.A**

ARIMA(0,1,0)(0,1,0)[4]	: 846.766
ARIMA(0,1,0)(0,1,1)[4]	: 846.379
ARIMA(0,1,0)(0,1,2)[4]	: 848.8552
ARIMA(0,1,0)(1,1,0)[4]	: 846.9605
ARIMA(0,1,0)(1,1,1)[4]	: 848.8668
ARIMA(0,1,0)(1,1,2)[4]	: 851.2837
ARIMA(0,1,0)(2,1,0)[4]	: 849.0652
ARIMA(0,1,0)(2,1,1)[4]	: 851.5726
ARIMA(0,1,0)(2,1,2)[4]	: 854.135
ARIMA(0,1,1)(0,1,0)[4]	: 847.7098
ARIMA(0,1,1)(0,1,1)[4]	: 847.2012
ARIMA(0,1,1)(0,1,2)[4]	: 849.9198
ARIMA(0,1,1)(1,1,0)[4]	: 848.0643
ARIMA(0,1,1)(1,1,1)[4]	: 849.9305
ARIMA(0,1,1)(1,1,2)[4]	: Inf
ARIMA(0,1,1)(2,1,0)[4]	: 849.7559
ARIMA(0,1,1)(2,1,1)[4]	: 852.6241
ARIMA(0,1,1)(2,1,2)[4]	: 855.3085
ARIMA(0,1,2)(0,1,0)[4]	: 847.8679
ARIMA(0,1,2)(0,1,1)[4]	: 848.098
ARIMA(0,1,2)(0,1,2)[4]	: 851.0545
ARIMA(0,1,2)(1,1,0)[4]	: 848.5144
ARIMA(0,1,2)(1,1,1)[4]	: 851.0629
ARIMA(0,1,2)(1,1,2)[4]	: 854.2579
ARIMA(0,1,2)(2,1,0)[4]	: 851.1098
ARIMA(0,1,2)(2,1,1)[4]	: 854.3062
ARIMA(0,1,3)(0,1,0)[4]	: Inf
ARIMA(0,1,3)(0,1,1)[4]	: 847.9611
ARIMA(0,1,3)(0,1,2)[4]	: 851.1719
ARIMA(0,1,3)(1,1,0)[4]	: 849.2303
ARIMA(0,1,3)(1,1,1)[4]	: 851.1905
ARIMA(0,1,3)(2,1,0)[4]	: 851.4518
ARIMA(1,1,0)(0,1,0)[4]	: 848.2756
ARIMA(1,1,0)(0,1,1)[4]	: 848.0224
ARIMA(1,1,0)(0,1,2)[4]	: 850.7415
ARIMA(1,1,0)(1,1,0)[4]	: 848.7591
ARIMA(1,1,0)(1,1,1)[4]	: 850.7497
ARIMA(1,1,0)(1,1,2)[4]	: Inf
ARIMA(1,1,0)(2,1,0)[4]	: 850.803
ARIMA(1,1,0)(2,1,1)[4]	: 853.5973
ARIMA(1,1,0)(2,1,2)[4]	: 856.2648
ARIMA(1,1,1)(0,1,0)[4]	: 849.526
ARIMA(1,1,1)(0,1,1)[4]	: 849.6361
ARIMA(1,1,1)(0,1,2)[4]	: 852.5848
ARIMA(1,1,1)(1,1,0)[4]	: 850.3372
ARIMA(1,1,1)(1,1,1)[4]	: 852.6051
ARIMA(1,1,1)(1,1,2)[4]	: Inf
ARIMA(1,1,1)(2,1,0)[4]	: 852.4528
ARIMA(1,1,1)(2,1,1)[4]	: 855.6316

ARIMA(1,1,2)(0,1,0)[4]	: Inf
ARIMA(1,1,2)(0,1,1)[4]	: Inf
ARIMA(1,1,2)(0,1,2)[4]	: Inf
ARIMA(1,1,2)(1,1,0)[4]	: Inf
ARIMA(1,1,2)(1,1,1)[4]	: Inf
ARIMA(1,1,2)(2,1,0)[4]	: Inf
ARIMA(1,1,3)(0,1,0)[4]	: Inf
ARIMA(1,1,3)(0,1,1)[4]	: Inf
ARIMA(1,1,3)(1,1,0)[4]	: Inf
ARIMA(2,1,0)(0,1,0)[4]	: 848.4259
ARIMA(2,1,0)(0,1,1)[4]	: 846.8403
ARIMA(2,1,0)(0,1,2)[4]	: 849.7123
ARIMA(2,1,0)(1,1,0)[4]	: 847.9067
ARIMA(2,1,0)(1,1,1)[4]	: 849.7692
ARIMA(2,1,0)(1,1,2)[4]	: Inf
ARIMA(2,1,0)(2,1,0)[4]	: 849.6282
ARIMA(2,1,0)(2,1,1)[4]	: 852.7977
ARIMA(2,1,1)(0,1,0)[4]	: Inf
ARIMA(2,1,1)(0,1,1)[4]	: 847.8711
ARIMA(2,1,1)(0,1,2)[4]	: 850.9448
ARIMA(2,1,1)(1,1,0)[4]	: 848.756
ARIMA(2,1,1)(1,1,1)[4]	: Inf
ARIMA(2,1,1)(2,1,0)[4]	: 851.1217
ARIMA(2,1,2)(0,1,0)[4]	: 849.1905
ARIMA(2,1,2)(0,1,1)[4]	: 851.0711
ARIMA(2,1,2)(1,1,0)[4]	: 851.8588
ARIMA(2,1,3)(0,1,0)[4]	: Inf
ARIMA(3,1,0)(0,1,0)[4]	: 848.7418
ARIMA(3,1,0)(0,1,1)[4]	: 847.9768
ARIMA(3,1,0)(0,1,2)[4]	: 851.2232
ARIMA(3,1,0)(1,1,0)[4]	: 848.982
ARIMA(3,1,0)(1,1,1)[4]	: 851.2107
ARIMA(3,1,0)(2,1,0)[4]	: 851.5117
ARIMA(3,1,1)(0,1,0)[4]	: 849.472
ARIMA(3,1,1)(0,1,1)[4]	: 851.1583
ARIMA(3,1,1)(1,1,0)[4]	: 851.8778
ARIMA(3,1,2)(0,1,0)[4]	: Inf

Best model: ARIMA(0,1,0)(0,1,1)[4]

Series: VendasVVAR

ARIMA(0,1,0)(0,1,1)[4]

Coefficients:

sma1

-0.5097

s.e. 0.2530

sigma^2 estimated as 6.652e+11: log likelihood=-420.95

AIC=845.9 AICc=846.38 BIC=848.56

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	9384289	8339051	10429528	7785735	10982844
2021 Q3	10949942	9471751	12428132	8689244	13210639
2021 Q4	9289543	7479137	11099949	6520766	12058321
2022 Q1	9143424	7052947	11233901	5946315	12340533
2022 Q2	10447580	7840572	13054589	6460505	14434656
2022 Q3	12013233	8976311	15050155	7368662	16657804
2022 Q4	10352834	6939728	13765940	5132939	15572730
2023 Q1	10206715	6454956	13958474	4468895	15944535

APÊNDICE E – MODELO HOLT-WINTERS – VIA VAREJO S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	8318619	6977215	9660023	6267118	10370119
2021 Q3	10172691	7897064	12448317	6692420	13652962
2021 Q4	8772317	6335380	11209255	5045343	12499291
2022 Q1	8330492	5598217	11062767	4151838	12509146
2022 Q2	8654675	5399820	11909531	3676803	13632548
2022 Q3	10579539	6104315	15054763	3735275	17423803
2022 Q4	9119686	4839565	13399807	2573806	15665567
2023 Q1	8657132	4195267	13118998	1833298	15480967

APÊNDICE F – MODELO MÉDIA MÓVEL CENTRADA – VIA VAREJO S.A

	Qtr1	Qtr2	Qtr3	Qtr4
2013			9274489	7979578
2014	7382852	7620793	8950952	7175304
2015	7675358	6189039	5441367	5489056
2016	6683500	5780446	6791895	6069346
2017	5689203	5919457	7353611	6371202
2018	7395080	6396554	5850037	6054838
2019	7632014	6789370	7877292	7017203
2020	6834609	7299190	9438684	8671079
2021	10430111	9384993	8946950	9581719
2022	12294057	11088080	13385235	12077252
2023	11536755			

**APÊNDICE G – MODELOS ARIMA ANALISADOS E BEST MODEL –
AMERICANAS S.A**

ARIMA(0,0,0)(0,1,0)[4]	: 1189.642
ARIMA(0,0,0)(0,1,0)[4] with drift	: 1189.556
ARIMA(0,0,0)(0,1,1)[4]	: 1188.019
ARIMA(0,0,0)(0,1,1)[4] with drift	: 1188.246
ARIMA(0,0,0)(0,1,2)[4]	: 1187.75
ARIMA(0,0,0)(0,1,2)[4] with drift	: 1188.381
ARIMA(0,0,0)(1,1,0)[4]	: 1188.238
ARIMA(0,0,0)(1,1,0)[4] with drift	: 1188.59
ARIMA(0,0,0)(1,1,1)[4]	: 1189.935
ARIMA(0,0,0)(1,1,1)[4] with drift	: 1190.396
ARIMA(0,0,0)(1,1,2)[4]	: 1185.882
ARIMA(0,0,0)(1,1,2)[4] with drift	: Inf
ARIMA(0,0,0)(2,1,0)[4]	: 1187.888
ARIMA(0,0,0)(2,1,0)[4] with drift	: 1188.142
ARIMA(0,0,0)(2,1,1)[4]	: 1179.818
ARIMA(0,0,0)(2,1,1)[4] with drift	: Inf
ARIMA(0,0,0)(2,1,2)[4]	: Inf
ARIMA(0,0,0)(2,1,2)[4] with drift	: Inf
ARIMA(0,0,1)(0,1,0)[4]	: 1169.69
ARIMA(0,0,1)(0,1,0)[4] with drift	: 1170.271
ARIMA(0,0,1)(0,1,1)[4]	: 1169.951
ARIMA(0,0,1)(0,1,1)[4] with drift	: 1170.865
ARIMA(0,0,1)(0,1,2)[4]	: 1172.359
ARIMA(0,0,1)(0,1,2)[4] with drift	: Inf
ARIMA(0,0,1)(1,1,0)[4]	: 1170.471
ARIMA(0,0,1)(1,1,0)[4] with drift	: 1171.37
ARIMA(0,0,1)(1,1,1)[4]	: 1172.404
ARIMA(0,0,1)(1,1,1)[4] with drift	: 1173.446
ARIMA(0,0,1)(1,1,2)[4]	: Inf
ARIMA(0,0,1)(1,1,2)[4] with drift	: Inf
ARIMA(0,0,1)(2,1,0)[4]	: 1171.323
ARIMA(0,0,1)(2,1,0)[4] with drift	: 1172.235
ARIMA(0,0,1)(2,1,1)[4]	: 1169.072
ARIMA(0,0,1)(2,1,1)[4] with drift	: Inf
ARIMA(0,0,1)(2,1,2)[4]	: Inf
ARIMA(0,0,1)(2,1,2)[4] with drift	: Inf
ARIMA(0,0,2)(0,1,0)[4]	: 1166.936
ARIMA(0,0,2)(0,1,0)[4] with drift	: 1167.842
ARIMA(0,0,2)(0,1,1)[4]	: 1169.194
ARIMA(0,0,2)(0,1,1)[4] with drift	: 1170.268
ARIMA(0,0,2)(0,1,2)[4]	: 1170.003
ARIMA(0,0,2)(0,1,2)[4] with drift	: Inf
ARIMA(0,0,2)(1,1,0)[4]	: 1169.269
ARIMA(0,0,2)(1,1,0)[4] with drift	: 1170.336
ARIMA(0,0,2)(1,1,1)[4]	: 1171.679
ARIMA(0,0,2)(1,1,1)[4] with drift	: 1172.899
ARIMA(0,0,2)(1,1,2)[4]	: Inf
ARIMA(0,0,2)(1,1,2)[4] with drift	: Inf
ARIMA(0,0,2)(2,1,0)[4]	: 1170.929
ARIMA(0,0,2)(2,1,0)[4] with drift	: 1172.044

ARIMA(0,0,2)(2,1,1)[4]	: Inf
ARIMA(0,0,2)(2,1,1)[4] with drift	: Inf
ARIMA(0,0,3)(0,1,0)[4]	: 1160.379
ARIMA(0,0,3)(0,1,0)[4] with drift	: 1161.813
ARIMA(0,0,3)(0,1,1)[4]	: 1158.69
ARIMA(0,0,3)(0,1,1)[4] with drift	: 1160.596
ARIMA(0,0,3)(0,1,2)[4]	: 1160.81
ARIMA(0,0,3)(0,1,2)[4] with drift	: 1163.003
ARIMA(0,0,3)(1,1,0)[4]	: 1158.429
ARIMA(0,0,3)(1,1,0)[4] with drift	: 1160.482
ARIMA(0,0,3)(1,1,1)[4]	: 1160.943
ARIMA(0,0,3)(1,1,1)[4] with drift	: 1163.145
ARIMA(0,0,3)(2,1,0)[4]	: 1160.831
ARIMA(0,0,3)(2,1,0)[4] with drift	: 1163.007
ARIMA(1,0,0)(0,1,0)[4]	: 1154.363
ARIMA(1,0,0)(0,1,0)[4] with drift	: 1155.897
ARIMA(1,0,0)(0,1,1)[4]	: 1156.543
ARIMA(1,0,0)(0,1,1)[4] with drift	: 1158.214
ARIMA(1,0,0)(0,1,2)[4]	: 1158.397
ARIMA(1,0,0)(0,1,2)[4] with drift	: 1160.076
ARIMA(1,0,0)(1,1,0)[4]	: 1156.578
ARIMA(1,0,0)(1,1,0)[4] with drift	: 1158.249
ARIMA(1,0,0)(1,1,1)[4]	: Inf
ARIMA(1,0,0)(1,1,1)[4] with drift	: Inf
ARIMA(1,0,0)(1,1,2)[4]	: Inf
ARIMA(1,0,0)(1,1,2)[4] with drift	: Inf
ARIMA(1,0,0)(2,1,0)[4]	: 1158.615
ARIMA(1,0,0)(2,1,0)[4] with drift	: 1160.39
ARIMA(1,0,0)(2,1,1)[4]	: Inf
ARIMA(1,0,0)(2,1,1)[4] with drift	: Inf
ARIMA(1,0,0)(2,1,2)[4]	: Inf
ARIMA(1,0,0)(2,1,2)[4] with drift	: Inf
ARIMA(1,0,1)(0,1,0)[4]	: 1156.076
ARIMA(1,0,1)(0,1,0)[4] with drift	: 1157.788
ARIMA(1,0,1)(0,1,1)[4]	: 1158.342
ARIMA(1,0,1)(0,1,1)[4] with drift	: 1160.203
ARIMA(1,0,1)(0,1,2)[4]	: 1160.562
ARIMA(1,0,1)(0,1,2)[4] with drift	: 1162.469
ARIMA(1,0,1)(1,1,0)[4]	: 1158.375
ARIMA(1,0,1)(1,1,0)[4] with drift	: 1160.237
ARIMA(1,0,1)(1,1,1)[4]	: Inf
ARIMA(1,0,1)(1,1,1)[4] with drift	: Inf
ARIMA(1,0,1)(1,1,2)[4]	: Inf
ARIMA(1,0,1)(1,1,2)[4] with drift	: Inf
ARIMA(1,0,1)(2,1,0)[4]	: 1160.752
ARIMA(1,0,1)(2,1,0)[4] with drift	: 1162.733
ARIMA(1,0,1)(2,1,1)[4]	: Inf
ARIMA(1,0,1)(2,1,1)[4] with drift	: Inf

ARIMA(1,0,2)(0,1,0)[4]	: 1158.506
ARIMA(1,0,2)(0,1,0)[4] with drift	: 1160.353
ARIMA(1,0,2)(0,1,1)[4]	: 1160.924
ARIMA(1,0,2)(0,1,1)[4] with drift	: 1162.935
ARIMA(1,0,2)(0,1,2)[4]	: 1163.318
ARIMA(1,0,2)(0,1,2)[4] with drift	: 1165.392
ARIMA(1,0,2)(1,1,0)[4]	: 1160.954
ARIMA(1,0,2)(1,1,0)[4] with drift	: 1162.965
ARIMA(1,0,2)(1,1,1)[4]	: Inf
ARIMA(1,0,2)(1,1,1)[4] with drift	: Inf
ARIMA(1,0,2)(2,1,0)[4]	: 1163.502
ARIMA(1,0,2)(2,1,0)[4] with drift	: 1165.648
ARIMA(1,0,3)(0,1,0)[4]	: 1159.95
ARIMA(1,0,3)(0,1,0)[4] with drift	: 1161.851
ARIMA(1,0,3)(0,1,1)[4]	: 1161.267
ARIMA(1,0,3)(0,1,1)[4] with drift	: 1163.384
ARIMA(1,0,3)(1,1,0)[4]	: Inf
ARIMA(1,0,3)(1,1,0)[4] with drift	: 1163.353
ARIMA(2,0,0)(0,1,0)[4]	: 1156.091
ARIMA(2,0,0)(0,1,0)[4] with drift	: 1157.797
ARIMA(2,0,0)(0,1,1)[4]	: 1158.37
ARIMA(2,0,0)(0,1,1)[4] with drift	: 1160.224
ARIMA(2,0,0)(0,1,2)[4]	: 1160.597
ARIMA(2,0,0)(0,1,2)[4] with drift	: 1162.5
ARIMA(2,0,0)(1,1,0)[4]	: 1158.4
ARIMA(2,0,0)(1,1,0)[4] with drift	: 1160.256
ARIMA(2,0,0)(1,1,1)[4]	: Inf
ARIMA(2,0,0)(1,1,1)[4] with drift	: Inf
ARIMA(2,0,0)(1,1,2)[4]	: Inf
ARIMA(2,0,0)(1,1,2)[4] with drift	: Inf
ARIMA(2,0,0)(2,1,0)[4]	: 1160.776
ARIMA(2,0,0)(2,1,0)[4] with drift	: 1162.75
ARIMA(2,0,0)(2,1,1)[4]	: Inf
ARIMA(2,0,0)(2,1,1)[4] with drift	: Inf
ARIMA(2,0,1)(0,1,0)[4]	: 1158.53
ARIMA(2,0,1)(0,1,0)[4] with drift	: 1160.382
ARIMA(2,0,1)(0,1,1)[4]	: 1160.94
ARIMA(2,0,1)(0,1,1)[4] with drift	: 1162.953
ARIMA(2,0,1)(0,1,2)[4]	: 1163.318
ARIMA(2,0,1)(0,1,2)[4] with drift	: 1165.392
ARIMA(2,0,1)(1,1,0)[4]	: 1160.971
ARIMA(2,0,1)(1,1,0)[4] with drift	: 1162.986
ARIMA(2,0,1)(1,1,1)[4]	: Inf
ARIMA(2,0,1)(1,1,1)[4] with drift	: Inf
ARIMA(2,0,1)(2,1,0)[4]	: 1163.507
ARIMA(2,0,1)(2,1,0)[4] with drift	: 1165.655
ARIMA(2,0,2)(0,1,0)[4]	: 1157.438
ARIMA(2,0,2)(0,1,0)[4] with drift	: Inf
ARIMA(2,0,2)(0,1,1)[4]	: Inf
ARIMA(2,0,2)(0,1,1)[4] with drift	: Inf
ARIMA(2,0,2)(1,1,0)[4]	: Inf

```

ARIMA(2,0,2)(1,1,0)[4] with drift : 1165.064
ARIMA(2,0,3)(0,1,0)[4] : 1162.118
ARIMA(2,0,3)(0,1,0)[4] with drift : 1164.28
ARIMA(3,0,0)(0,1,0)[4] : 1158.465
ARIMA(3,0,0)(0,1,0)[4] with drift : 1160.327
ARIMA(3,0,0)(0,1,1)[4] : 1160.847
ARIMA(3,0,0)(0,1,1)[4] with drift : 1162.872
ARIMA(3,0,0)(0,1,2)[4] : 1163.198
ARIMA(3,0,0)(0,1,2)[4] with drift : 1165.27
ARIMA(3,0,0)(1,1,0)[4] : 1160.883
ARIMA(3,0,0)(1,1,0)[4] with drift : 1162.909
ARIMA(3,0,0)(1,1,1)[4] : Inf
ARIMA(3,0,0)(1,1,1)[4] with drift : Inf
ARIMA(3,0,0)(2,1,0)[4] : 1163.428
ARIMA(3,0,0)(2,1,0)[4] with drift : 1165.589
ARIMA(3,0,1)(0,1,0)[4] : 1159.858
ARIMA(3,0,1)(0,1,0)[4] with drift : 1161.897
ARIMA(3,0,1)(0,1,1)[4] : 1162.614
ARIMA(3,0,1)(0,1,1)[4] with drift : 1164.82
ARIMA(3,0,1)(1,1,0)[4] : 1162.614
ARIMA(3,0,1)(1,1,0)[4] with drift : 1164.82
ARIMA(3,0,2)(0,1,0)[4] : Inf
ARIMA(3,0,2)(0,1,0)[4] with drift : 1164.778

```

Best model: ARIMA(1,0,0)(0,1,0)[4]

Series: VendasAMER

ARIMA(1,0,0)(0,1,0)[4]

Coefficients:

ar1

0.8135

s.e. 0.0975

sigma^2 estimated as 8.886e+10: log likelihood=-575.02

AIC=1154.05 AICc=1154.36 BIC=1157.47

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	9384289	8339051	10429528	7785735	10982844
2021 Q3	10949942	9471751	12428132	8689244	13210639
2021 Q4	9289543	7479137	11099949	6520766	12058321
2022 Q1	9143424	7052947	11233901	5946315	12340533
2022 Q2	10447580	7840572	13054589	6460505	14434656
2022 Q3	12013233	8976311	15050155	7368662	16657804
2022 Q4	10352834	6939728	13765940	5132939	15572730
2023 Q1	10206715	6454956	13958474	4468895	15944535

APÊNDICE H – MODELO HOLT-WINTERS – AMERICANAS S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	2834450	2329593	3339307	2062337.4	3606562
2021 Q3	3083708	2333820	3833597	1936852.6	4230564
2021 Q4	4057078	2852049	5262108	2214145.1	5900012
2022 Q1	2956436	1936421	3976451	1396458.1	4516414
2022 Q2	2945776	1798645	4092907	1191390.0	4700161
2022 Q3	3203647	1821636	4585657	1090044.5	5317249
2022 Q4	4213356	2226130	6200581	1174157.1	7252554
2023 Q1	3069231	1501867	4636594	672155.3	5466306

APÊNDICE I – MODELO MÉDIA MÓVEL CENTRADA – AMERICANAS S.A

	Qtr1	Qtr2	Qtr3	Qtr4
2010			1705291	2183078
2011	1543389	1505862	1590601	2008335
2012	1472710	1563310	1798151	2393978
2013	1784704	1880370	2159784	2930630
2014	2221915	2339268	2640168	3444110
2015	2499903	2490373	2585066	3155450
2016	2221989	2183156	2304094	2865900
2017	1988903	1800893	1780279	2245846
2018	1595179	1588097	1688011	2114740
2019	1537148	1580540	1785833	2504111
2020	2027913	2236559	2652506	2840122
2021	2133272	2227060	2515648	3389864
2022	2585724	2737592	3131517	4266795
2023	3285956			

**APÊNDICE J – MODELOS ARIMA ANALISADOS E BEST MODEL – LOJAS
RENNER S.A**

ARIMA(0,1,0)(0,1,0)[4]	: 1125.81
ARIMA(0,1,0)(0,1,1)[4]	: 1128.029
ARIMA(0,1,0)(0,1,2)[4]	: 1129.721
ARIMA(0,1,0)(1,1,0)[4]	: 1128.029
ARIMA(0,1,0)(1,1,1)[4]	: Inf
ARIMA(0,1,0)(1,1,2)[4]	: 1132.07
ARIMA(0,1,0)(2,1,0)[4]	: 1129.822
ARIMA(0,1,0)(2,1,1)[4]	: Inf
ARIMA(0,1,0)(2,1,2)[4]	: 1134.481
ARIMA(0,1,1)(0,1,0)[4]	: 1122.838
ARIMA(0,1,1)(0,1,1)[4]	: 1124.773
ARIMA(0,1,1)(0,1,2)[4]	: 1126.793
ARIMA(0,1,1)(1,1,0)[4]	: 1124.567
ARIMA(0,1,1)(1,1,1)[4]	: Inf
ARIMA(0,1,1)(1,1,2)[4]	: 1129.024
ARIMA(0,1,1)(2,1,0)[4]	: Inf
ARIMA(0,1,1)(2,1,1)[4]	: Inf
ARIMA(0,1,1)(2,1,2)[4]	: Inf
ARIMA(0,1,2)(0,1,0)[4]	: 1121.353
ARIMA(0,1,2)(0,1,1)[4]	: 1123.737
ARIMA(0,1,2)(0,1,2)[4]	: 1126.3
ARIMA(0,1,2)(1,1,0)[4]	: 1123.718
ARIMA(0,1,2)(1,1,1)[4]	: Inf
ARIMA(0,1,2)(1,1,2)[4]	: 1128.965
ARIMA(0,1,2)(2,1,0)[4]	: 1126.27
ARIMA(0,1,2)(2,1,1)[4]	: 1129.055
ARIMA(0,1,3)(0,1,0)[4]	: 1123.739
ARIMA(0,1,3)(0,1,1)[4]	: 1126.327
ARIMA(0,1,3)(0,1,2)[4]	: 1129.037
ARIMA(0,1,3)(1,1,0)[4]	: 1126.317
ARIMA(0,1,3)(1,1,1)[4]	: Inf
ARIMA(0,1,3)(2,1,0)[4]	: 1129.008
ARIMA(1,1,0)(0,1,0)[4]	: 1125.903
ARIMA(1,1,0)(0,1,1)[4]	: 1128.218
ARIMA(1,1,0)(0,1,2)[4]	: 1129.619
ARIMA(1,1,0)(1,1,0)[4]	: 1128.197
ARIMA(1,1,0)(1,1,1)[4]	: Inf
ARIMA(1,1,0)(1,1,2)[4]	: 1132.214
ARIMA(1,1,0)(2,1,0)[4]	: Inf
ARIMA(1,1,0)(2,1,1)[4]	: Inf
ARIMA(1,1,0)(2,1,2)[4]	: 1134.98
ARIMA(1,1,1)(0,1,0)[4]	: 1121.421
ARIMA(1,1,1)(0,1,1)[4]	: 1123.896
ARIMA(1,1,1)(0,1,2)[4]	: 1126.219
ARIMA(1,1,1)(1,1,0)[4]	: 1123.896
ARIMA(1,1,1)(1,1,1)[4]	: 1126.393
ARIMA(1,1,1)(1,1,2)[4]	: 1128.907
ARIMA(1,1,1)(2,1,0)[4]	: 1126.106
ARIMA(1,1,1)(2,1,1)[4]	: 1128.87
ARIMA(1,1,2)(0,1,0)[4]	: 1123.686
ARIMA(1,1,2)(0,1,1)[4]	: 1126.299


```

ARIMA(1,1,2)(0,1,2)[4] : 1128.955
ARIMA(1,1,2)(1,1,0)[4] : 1126.295
ARIMA(1,1,2)(1,1,1)[4] : Inf
ARIMA(1,1,2)(2,1,0)[4] : 1128.879
ARIMA(1,1,3)(0,1,0)[4] : 1126.205
ARIMA(1,1,3)(0,1,1)[4] : 1128.967
ARIMA(1,1,3)(1,1,0)[4] : 1128.958
ARIMA(2,1,0)(0,1,0)[4] : 1124.797
ARIMA(2,1,0)(0,1,1)[4] : 1126.345
ARIMA(2,1,0)(0,1,2)[4] : 1128.498
ARIMA(2,1,0)(1,1,0)[4] : 1125.872
ARIMA(2,1,0)(1,1,1)[4] : Inf
ARIMA(2,1,0)(1,1,2)[4] : 1131.077
ARIMA(2,1,0)(2,1,0)[4] : Inf
ARIMA(2,1,0)(2,1,1)[4] : 1131.077
ARIMA(2,1,1)(0,1,0)[4] : 1123.766
ARIMA(2,1,1)(0,1,1)[4] : 1126.388
ARIMA(2,1,1)(0,1,2)[4] : 1128.977
ARIMA(2,1,1)(1,1,0)[4] : 1126.388
ARIMA(2,1,1)(1,1,1)[4] : Inf
ARIMA(2,1,1)(2,1,0)[4] : 1128.883
ARIMA(2,1,2)(0,1,0)[4] : Inf
ARIMA(2,1,2)(0,1,1)[4] : Inf
ARIMA(2,1,2)(1,1,0)[4] : Inf
ARIMA(2,1,3)(0,1,0)[4] : Inf
ARIMA(3,1,0)(0,1,0)[4] : 1125.354
ARIMA(3,1,0)(0,1,1)[4] : 1126.808
ARIMA(3,1,0)(0,1,2)[4] : 1129.426
ARIMA(3,1,0)(1,1,0)[4] : 1126.566
ARIMA(3,1,0)(1,1,1)[4] : 1129.334
ARIMA(3,1,0)(2,1,0)[4] : 1129.342
ARIMA(3,1,1)(0,1,0)[4] : 1126.165
ARIMA(3,1,1)(0,1,1)[4] : Inf
ARIMA(3,1,1)(1,1,0)[4] : 1129.109
ARIMA(3,1,2)(0,1,0)[4] : Inf

```

Best model: ARIMA(0,1,2)(0,1,0)[4]

Series: VendasRENNER
ARIMA(0,1,2)(0,1,0)[4]

Coefficients:

	ma1	ma2
	-0.4353	-0.3307
s.e.	0.1526	0.1659

sigma^2 estimated as 7.654e+10: log likelihood=-557.34
AIC=1120.69 AICc=1121.35 BIC=1125.75

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	245672.317	-108872.68	600217.3	-296557.47	787902.1
2021 Q3	1284099.588	876934.72	1691264.5	661394.66	1906804.5
2021 Q4	2402678.588	1987147.49	2818209.7	1767178.62	3038178.6
2022 Q1	950160.588	526428.42	1373892.8	302118.16	1598203.0
2022 Q2	-8065.096	-617131.78	601001.6	-939552.21	923422.0
2022 Q3	1030362.175	358688.90	1702035.4	3126.55	2057597.8
2022 Q4	2148941.175	1457076.72	2840805.6	1090825.80	3207056.6
2023 Q1	696423.175	-15059.69	1407906.0	-391695.97	1784542.3

APÊNDICE K – MODELO HOLT-WINTERS – LOJAS RENNER S.A

	Point Forecast	Lo 80	Hi 80	Lo 95	Hi 95
2021 Q2	1587663	1246479.3	1928846	1065867.6	2109458
2021 Q3	1554432	1165110.0	1943754	959015.4	2149849
2021 Q4	2279970	1639414.1	2920526	1300324.1	3259616
2022 Q1	1392383	963646.8	1821120	736687.3	2048080
2022 Q2	1692162	1129926.8	2254396	832297.6	2552026
2022 Q3	1655087	1068307.0	2241868	757684.3	2552490
2022 Q4	2425255	1515455.5	3335055	1033836.7	3816674
2023 Q1	1479718	896183.9	2063252	587279.5	2372157

APÊNDICE L – MODELO MÉDIA MÓVEL CENTRADA – LOJAS RENNER S.A

	Qtr1	Qtr2	Qtr3	Qtr4
2010			1175752	1698407
2011	1064915	1260266	1250639	1796847
2012	1140774	1386185	1395160	1997700
2013	1249501	1484515	1468721	2107694
2014	1330210	1610704	1633450	2370514
2015	1496014	1756439	1703018	2386181
2016	1455521	1676976	1640649	2353008
2017	1487218	1791713	1788623	2551936
2018	1591815	1900299	1903779	2747450
2019	1731263	2051848	1984282	2498507
2020	1336259	1490849	1403534	2266889
2021	1407417	1652159	1619455	2297282
2022	1425864	1673340	1639771	2325496
2023	1443017			