



Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Engenharia de Produção



Trabalho de Conclusão de Curso

Modelo ARIMA para previsão e análise de receita de uma Startup no contexto do COVID-19

Carlos Henrique Neves Souza

**João Monlevade, MG
2020**

Carlos Henrique Neves Souza

**Modelo ARIMA para previsão e análise de receita
de uma Startup no contexto do COVID-19**

Trabalho de Conclusão de curso apresentado à Universidade Federal de Ouro Preto como parte dos requisitos para obtenção do Título de Bacharel em Engenharia de Produção pelo Instituto de Ciências Exatas e Aplicadas da Universidade Federal de Ouro Preto.

Orientador: Prof. Dr. Alexandre Xavier Martins

**Universidade Federal de Ouro Preto
João Monlevade
2020**

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

S729m Souza, Carlos Henrique Neves .
Modelo ARIMA para previsão e análise de receita de uma startup no
contexto do COVID-19. [manuscrito] / Carlos Henrique Neves Souza. -
2020.
29 f.

Orientador: Prof. Dr. Alexandre Martins.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de
Produção .

1. Administração de risco financeiro. 2. Controle preditivo. 3.
Empresas - Gestão de receita. I. Martins, Alexandre. II. Universidade
Federal de Ouro Preto. III. Título.

CDU 658.15

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



MINISTÉRIO DA EDUCAÇÃO
UNIVERSIDADE FEDERAL DE OURO PRETO
REITORIA
INSTITUTO DE CIÊNCIAS EXATAS E APLICADAS
DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO - ICEA

**FOLHA DE APROVAÇÃO****Carlos Henrique Neves Souza****Modelo ARIMA para previsão e análise de receita de uma Startup no contexto do COVID-19**

Membros da banca

Alexandre Xavier Martins - Doutor - UFOP

Diego Fernandes Pantuza Moura - Mestre - UFOP

Thiago Augusto de Oliveira Silva - Doutor - UFOP

Versão final

Aprovado em 14 de agosto de 2020

De acordo

Professor Orientador Alexandre Xavier Martins



Documento assinado eletronicamente por **Alexandre Xavier Martins**, COORDENADOR DO PROGRAMA DE POS GRADUACAO EM ENGENHARIA DE PRODUCAO/JM, em 20/08/2020, às 15:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0076173** e o código CRC **E72D216E**.

Referência: Caso responda este documento, indicar expressamente o Processo nº 23109.005887/2020-71

SEI nº 0076173

R. Diogo de Vasconcelos, 122, - Bairro Pilar Ouro Preto/MG, CEP 35400-000
Telefone: - www.ufop.br



TERMO DE RESPONSABILIDADE

O texto do Trabalho de Conclusão de Curso intitulado “Modelo ARIMA para previsão e análise de receita de uma Startup no contexto do COVID-19” é de minha inteira responsabilidade. Declaro que não há utilização indevida de texto, material fotográfico ou qualquer outro material pertencente a terceiros sem o devido referenciamento ou consentimento dos referidos autores.

João Monlevade, 20 de Agosto de 2020.

Carlos Henrique Neves Souza

Agradecimentos

Primeiramente e acima de tudo, gostaria de agradecer a minha família, sem ela o meu crescimento não seria possível. Foi por meio de confiança, inspiração e admiração que adquiri energia para continuar a busca pelos meus sonhos. Não obstante, agradeço aos meus amigos, que vivenciaram cada dia da minha luta de conseguir sempre buscar se tornar uma pessoa melhor, sendo minha fuga emocional em tempos difíceis. Aos meus professores, posso dizer que mudaram a minha vida, trouxeram uma grande noção da realidade e responsabilidade social, muito além do conhecimento de sala de aula. Sem essas três vertentes eu não seria o que eu sou e a vida nos mostra cada vez mais o quão importante é a educação e o bom convívio para o crescimento do ser humano. Jamais reclamarei sobre os tempos vividos, apenas amar o que vivi e o que irei viver. Obrigado a todos, dedico de coração esta etapa da minha vida.

"Minha fórmula para a grandeza no homem é amor-fati: não querer nada de outro modo, nem para diante nem para trás, nem em toda eternidade. Não meramente suportar o necessário, e menos ainda dissimulá-lo – todo idealismo é mendacidade diante do necessário -, mas amá-lo"

-Friedrich Nietzsche

Resumo

Empresas de tecnologias tem como principal objetivo o desenvolvimento de produtos ou serviços disruptivos. Para isso, devem enfrentar um ambiente de extrema incerteza. O gerenciamento de risco de tais ambientes é um dos principais desafios de uma *startup*. Nesse contexto, podemos citar dois eventos que impactaram o mercado brasileiro, a Greve dos Caminhoneiros em 2018 e a Pandemia do COVID-19 em 2020. A tomada de decisão em tais cenários pode ser auxiliada pela previsão e análise das receitas da empresa ao longo do tempo. O presente trabalho tem como objetivo aplicar o Modelo de Média Movel Integrado Autoregressivo (ARIMA) na previsão das receitas financeiras de uma empresa de tecnologia em Minas Gerais. Foi realizada uma análise das séries temporais no período entre 2018 e 2020, considerando os cenários com e sem COVID-19. Seguindo a metodologia Box-Jenkins, o modelo ARIMA(2,1,2) apresentou um melhor ajuste para ambos os cenários. Dessa forma, a aplicação do modelo deve ser interpretada como uma ferramenta de auxílio ao gerenciamento de risco e tomada de decisão, podendo assim decidir até quando reduzir custos ou aumentar os investimentos.

Palavras-chave: Startup, estatística, modelos preditivos, COVID-19, Box-Jenkins.

Abstract

Technology companies have as main objective the development of disruptive products or services. For that, they must face an environment of extreme uncertainty. The risk management of such environments is one of the main challenges of a textit startup. In this context, we can mention two events that impacted the Brazilian market, the Truckers' Strike in 2018 and the COVID-19 Pandemic in 2020. Decision making in such scenarios can be aided by forecasting and analyzing the company's revenues over the time. This work aims to apply the Autoregressive Integrated Moving Average Model (ARIMA) in the forecast of financial revenues of a technology company in Minas Gerais. An analysis of the time series was carried out in the period between 2018 and 2020, considering the scenarios with and without COVID-19. Following the Box-Jenkins methodology, the ARIMA model (2,1,2) presented a better fit for both scenarios. Thus, the application of the model should be interpreted as a tool to assist risk management and decision making, thus being able to decide even when to reduce costs or increase investments.

Keywords: Startup, predictive models, statistic, COVID-19, Box-Jenkins.

Lista de ilustrações

Figura 1 – Gráfico de Autocorrelação Série Independente	10
Figura 2 – Gráfico de Autocorrelação Curto-prazo	11
Figura 3 – Diagrama de Autocorrelação e Autocorrelação Parcial	12
Figura 4 – Resultado do ADCF Não Estacionário	13
Figura 5 – Relação das receitas Antes e Depois do Covid-19	15
Figura 6 – Validação da tendência em ambas observações	17
Figura 7 – Análise do resultado do teste ADCF	17
Figura 8 – Transformação dos dados por logaritmo	18
Figura 9 – Teste para Diferença entre médias móveis	19
Figura 10 – Diferença por deslocamento dos períodos de Tempo	20
Figura 11 – Comparação dos gráficos de Autocorrelação e Autocorrelação Parcial	21
Figura 12 – Comparação dos resíduos dos modelos ARIMA	23
Figura 13 – Modelo ARIMA(2,1,2) Pré Covid	24
Figura 14 – Distribuição de resíduos Pré-Covid	25
Figura 15 – Modelo ARIMA(2,1,2) Pós Covid-19	25
Figura 16 – Relação de previsão de receitas dos modelos	26

Lista de abreviaturas e siglas

ARIMA - Autoregressive integrated moving average

RSS - Root sum squared.

ACF - Auto-correlation function

PACF - Partial auto-correlation function

ADCF - Augmented Dickey-Fuller Test

Sumário

1	INTRODUÇÃO	1
1.1	Objetivos	2
1.1.1	Objetivo Geral	2
1.1.2	Objetivos Específicos	2
1.2	Justificativa	2
1.3	Organização do trabalho	2
2	METODOLOGIA DE PESQUISA	4
3	REVISÃO DE LITERATURA	5
3.1	Trabalhos semelhantes	5
3.2	Séries Temporais	5
3.3	Modelos de séries temporais	6
3.4	Posicionamento do presente trabalho	6
4	FUNDAMENTAÇÃO TEÓRICA	8
4.1	Série Temporal	8
4.1.1	Decomposição	8
4.1.2	Séries com Tendências	8
4.1.3	Séries Sazonais	9
4.1.4	Autocorrelação	9
4.1.4.1	Correlograma	9
4.1.4.2	Interpretações do Correlograma	10
4.2	Representação do modelo ARIMA	11
4.2.1	Diferenciação	11
4.2.2	Função de Autocorrelação	11
4.2.3	Função de Autocorrelação Parcial	12
4.3	Box-Jenkins	13
4.4	Dickey-Fuller Test	13
4.4.1	Análise do Resultado do ADCF	13
4.5	Análise residual	14
5	APLICAÇÃO DOS PASSOS DE BOX-JENKINS	15
5.1	Levantamento e tratamento dos Dados	15
5.2	Identificação das características	16
5.2.1	Aplicação da Diferenciação	16

5.3	Estimação dos Parâmetros ARIMA	21
5.4	Diagnóstico	22
6	RESULTADOS E DISCUSSÕES	24
7	CONCLUSÃO E TRABALHOS FUTUROS	27
	REFERÊNCIAS	28

1 Introdução

Uma *startup* é "uma instituição humana projetada para criar novos produtos e serviços sob condições de extrema incerteza." (RIES, 2011). Quando se pensa em *startup*, vem em mente sempre empresas grandiosas como Facebook, Amazon, Netflix, Google e Microsoft. Todas elas começaram pequenas e se tornaram gigantes mundialmente. Entretanto, o mundo da inovação não começou com estas gloriosas empresas.

A revolução da tecnologia começou em meados de 1950 com William Shockley, Prêmio Nobel de Física de 1956 pela invenção do transistor, que enxergou na baía de São Francisco, sua cidade natal, a oportunidade de criar uma empresa de semicondutores. Além de Shockley, existiu Frederick Therman, reitor da Universidade de Stanford, que incentivou na mesma época a criação de empresas compostas por alunos graduados e professores. Com este ambiente de pessoas notáveis iniciou-se uma gama de empresas, entre elas a Fairchild Semiconductor, a qual foi umas das primeiras a produzir circuitos integrados. Desde então, o desenvolvimento tecnológico cresceu no local, onde foi desenvolvida uma nova cultura para criação de empresas, chegando no que temos hoje como Vale do Silício (PENIDO, 2014).

Já no Brasil, o começo do ecossistema das *startups* começou entre 2010 e 2011 com alguns grupos de empresários incentivando o desenvolvimento local, porém o grande crescimento veio a partir de 2015, existiam 4151 *startups*, chegando a 12727 em 2019 (CARRILO, 2020). Dentro deste conjunto de novas empresas, foi fundada em 2015 uma *startup* mineira, sediada em Itabira. Tendo como função, ser uma aceleradora de resultado para postos de combustíveis por meio do programa de fidelidade e softwares de gestão das atividades do posto.

Em 2019, existiu a oportunidade de realizar o estágio curricular nesta *startup*, base do atual estudo. Relembrando a definição de Eric Rieis, *startups* são associadas a ambiente de extrema incerteza. Logo, vale citar dois pontos importantes que aconteceram nos últimos anos. A greve dos caminhoneiros em 2018, onde existiu a paralisação total do principal modal logístico do país, o rodoviário. Tal evento teve grande impacto na economia nacional e, particularmente, na indústria de comércio de combustível (MATOS, 2018). O que, por consequência, ocasionou em um histórico de queda de receita e recuperação da *startup*.

O mesmo ocorreu em 2020, com a paralisação do comércio nacional devido a restrição de circulação das pessoas em todas cidades do país e funcionamento exclusivo dos serviços essenciais, medida adotada pelo governo a fim de conter a pandemia gerada pelo Covid-19. De acordo com a pesquisa feita pela Digitais (2020), 77,7% das empresas tiveram impacto negativo, dentre elas 39% foram entre 40% e 100% de queda nas receitas. Segundo Losekann (2020), o mercado teve em média uma queda de 50% da demanda por combustíveis. Impactando direto no resultado financeiro da *startup*. Em vista deste cenário, foi possível identificar a oportunidade de realizar um trabalho de previsão de receita da empresa a partir de um modelo preditivo baseado na metodologia Box-Jenkins, que visa a criação de um panorama sobre o futuro, mitigando a

incerteza do negócio.

1.1 Objetivos

1.1.1 Objetivo Geral

O objetivo do presente estudo é apresentar um modelo preditivo de receita financeira que demonstre a diferença do comportamento antes e durante o evento do COVID-19.

1.1.2 Objetivos Específicos

- ✓ Realizar revisão da literatura
- ✓ Demonstrar estruturas das séries temporais
- ✓ Aplicar a metodologia Box-Jenkins.
- ✓ Analisar e interpretar os resultados.

1.2 Justificativa

Dado o momento de crise atual e o desconhecimento da curva de recuperação econômica, o presente trabalho propõe o desenvolvimento de uma ferramenta de previsibilidade. Ou seja, como seria o comportamento da receita, caso ela seguisse a tendência histórica sem os impactos do COVID-19, em contraposição à nova tendência, considerando os impactos de demanda da pandemia. Proporcionando, assim, uma visão aprimorada a cerca do futuro com um embasamento estatístico. Diante disso, o trabalho trará não só uma perspectiva, mas também uma forma de acompanhar o quão rápido a empresa se recuperará da antiga tendência, ao atualizar o modelo com novos dados de receita. Sendo assim, possível medir quanto os esforços atuais estão sendo efetivos do ponto de vista financeiro.

1.3 Organização do trabalho

O estudo foi dividido em 7 partes: o Capítulo 1 traz a visão do ambiente de uma *startup* e contextualiza os problemas e impactos que eventos imprevisíveis podem causar no financeiro de uma empresa, dessa forma justifica-se o presente trabalho, demonstrando a importância da realização do mesmo e a necessidade de um método matemático de previsão. O Capítulo 2 demonstra o passo a passo da metodologia. No Capítulo 3 traz a revisão de literatura, para relacionar trabalhos do mesmo tema e conceitos importantes para contextualização do tema. O Capítulo 4 possui a fundamentação teórica referente ao modelo auto-regressivo integrado de médias móveis. O Capítulo 5 apresenta a aplicação da metodologia Box-Jenkins. Seguindo, o

Capítulo 6 traz os resultados da aplicação, previsão do modelo e as análises sobre tais resultados. E, finalmente, as conclusões sobre o trabalho e propostas de possíveis trabalhos futuros no Capítulo 7.

2 Metodologia de pesquisa

Segundo Turrioni e Mello (2012), a pesquisa é classificada no contexto de sua natureza, objetivos, abordagens e método. A classificação por natureza significa como o trabalho será desenvolvido. Aqueles que possuem carácter que tende mais ao empírico são identificadas como aplicadas, enquanto as que voltam aos estudos de teorias são básicas.

Em Gil (2002), referente aos objetivos, pode ser dividida em exploratória, descritiva, explicativa e normativa. A exploratória busca demonstrar características intrínsecas, a descritiva procura estabelecer relações entre os pontos que criam sua estrutura, a explicativa age de modo a encontrar as justificativas. E, por fim, a normativa procura estudar um modelo já existente, gerando novos modelos ou adaptações.

Turrioni e Mello (2012) ainda separa a abordagem em 3 tipos: quantitativa, qualitativa, e combinada. Uma abordagem quantitativa procura entender um problema através de uma visão numérica e estatística, enquanto a abordagem qualitativa é a análise de informações de carácter não ergódico. Já a abordagem combinada, consiste na união de ambas as visões.

O método pode ser separado em experimento, pesquisa levantamento, modelagem e simulação, estudo de caso e pesquisa ação. Experimento se trata do estudo de um contexto, das variáveis envolvidas e de seus resultados. Pesquisa levantamento é utilizada quando há elaboração de um documento que leva ao contato direto com o público, levantando informações, gerando mais conhecimento sobre o público alvo. Modelagem e simulação é o uso de um modelo matemático para uma representação próxima da realidade, a fim de analisar as saídas do mesmo mediante a alterações. Estudo de caso é a dissecação do objeto de estudo para extrair o máximo de informação possível. E, por último, pesquisa ação é associada a resolução de algum problema estudado (MARCONI; LAKATOS, 2006).

Portanto, trata-se do estudo de um contexto real e análise de modelos matemáticos que visam auxiliar o processo de tomada de decisão em cima da previsão da receita financeira. O primeiro passo foi o levantamento dos dados da receita de 2018 a 2020 e estruturação dessa base no Excel. Posteriormente, feito uma revisão bibliográfica sobre os assuntos referentes a séries temporais. Após esta etapa, leitura e realização do modelo em Python, utilizando o ambiente virtual Jupyter. Ao final, análises e repasse dos resultados para empresa. Este trabalho pode ser classificado na perspectiva em sua natureza aplicada, quanto ao objetivo normativo, abordagem quantitativa e, por fim, método de modelagem.

3 Revisão de literatura

3.1 Trabalhos semelhantes

O trabalho traz uma visão sobre previsão de receita utilizando modelos de séries temporais em uma empresa privada. Alguns trabalhos aplicados sobre o mesmo tema abordam previsões na área pública, como Azevedo, Silva e Gatsios (2015), apresentam comparações de modelos para séries históricas no cálculo de ICMS de alguns estados brasileiros. Diferentemente da proposta apresentada em Neto, Moura e Forte (2013), onde a proposta é realizar o fluxo de caixa considerando cenários variados de risco por meio de um modelo baseado em Monte Carlo. Sendo um trabalho mais amplo de simulação.

3.2 Séries Temporais

Segundo Hamilton (1994), séries temporais são coleções de observações feitas sequencialmente ao longo do tempo. Ou seja, são dados que contém relações sequenciais não independentes. Justamente o fato de não serem independentes, as séries temporais exigem uma abordagem diferente dos modelos de regressões, que consideram independência das observações, não exigindo uma ordem entre as informações.

Em Ehlers (2009) demonstra que os dados de séries temporais existem em diferentes naturezas, abordando desde Ciências Econômicas(Produção Industrial, Taxa de juros, preços do mercado acionário) até Medicina(Eletrocardiograma, eletroencefalograma). E ainda cita como as principais características das séries temporais e suas complexidades:

- ✓ Observações correlacionadas são mais difíceis de analisar e requerem técnicas específicas;
- ✓ Precisa-se levar em conta a ordem temporal das observações;
- ✓ Fatores complicadores como presença de tendências e variação sazonal ou cíclica podem ser difíceis de estimar ou remover;
- ✓ A seleção de modelos pode ser bastante complicada, e as ferramentas podem ser de difícil interpretação;
- ✓ É mais difícil de lidar com observações perdidas e dados discrepantes devido à natureza sequencial.

3.3 Modelos de séries temporais

Hamilton (1994) fala sobre o modelo de séries temporais estacionárias autorregressivo de médias móveis (ARMA), visto que modelos de regressão não trazem muita informação á séries temporais devido a dependência entre os dados. O ARMA é a união de um termo autorregressivo (AR) e um termo de média móvel(MA). Tendo como parâmetros (p,q), sendo p o termo autorregressivo e q o termo de média móvel. Tiao e Tsay (1985) demonstra que para modelar uma série não estacionária é necessário utilizar uma variação do modelo ARMA, o modelo autorregressivo integrado de médias móveis ARIMA, sendo o I um fator integrador d, definido pela quantidade de diferenciação aplicada na série temporal até que se torne estacionária. Gerando ao ARIMA os parâmetros (p,d,q).

Em Brito (2019) há um exemplo de aplicação do modelo ARIMA fora do âmbito financeiro, para previsão de atendimentos em pontos de atenção em um hospital no estado de Minas Gerais. Mostrando a versatilidade e o grande leque de aplicação do modelo ARIMA. Foram criados dois modelos, um ARIMA(3,1,1) para previsão de atendimentos cardiológicos e um ARIMA(2,1,1) para previsão de atendimentos no serviço de Emergência e Urgência feito pelo enfermeiro. Oferecendo uma ferramenta de auxílio na tomada de decisão dos gestores do hospital.

Em Azevedo, Silva e Gatsios (2015) os modelos ARIMA criados para os estados de SP, MG, RJ, RS, PR, BA aumentaram a acurácia das previsões dos cálculos de arrecadação do ICMS, dando uma diferente perspectiva para a tomada de decisão de cada estado. Entretanto, este trabalho alerta sobre dois aspectos importantes, a necessidade de atualização do modelo com a entrada de novos dados e a questão da fragilidade do modelo em caso de mudanças bruscas no aspecto macroeconômico.

3.4 Posicionamento do presente trabalho

Assim, no contexto de previsão de receita a partir de uma série temporal, o presente trabalho visa aplicar o *framework* utilizado por Box-Jenkins para modelagem auto-regressiva integrada com média móvel(ARIMA). Como citado em Liu e Hudak (1994), a aplicação do Box-Jenkins tem várias vantagens, dentre elas, sua capacidade de modelar a partir de eventos exógenos. Onde neste trabalho existem dois eventos importantes, a Greve dos Caminhoneiros em 2018 e o COVID-19 em 2020, que causaram grande impacto na receita da empresa em estudo.

O presente tema de modelos preditivos de séries temporais é vasto e bem explorado na literatura internacional, entretanto quando se busca por previsões de receitas financeiras em empresas de alta imprevisibilidade no Brasil, o assunto se torna mais restrito. Servindo de justificativa para o estudo atual.

O processo de previsão não busca acertar exatamente os dados do futuro, tendo em vista em Mintzberg, Ahlstrand e Lampel (2000), previsões para mais de 2 anos se tornam quase

impraticáveis. No entanto, ter uma compreensão do comportamento do movimento da série. De forma a servir de direção para tomadas de decisões estratégicas, sendo de extrema utilidade no ambiente de uma Startup.

4 Fundamentação teórica

O estudo presente se baseou principalmente na metodologia Box-Jenkins, diz que o modelo ARIMA é recomendado quando o processo estocástico é não estacionário, Box e Jenkins (1976). Foi utilizado da demonstração da curva da média móvel e curva de desvio padrão para verificação das características da série temporal. Como se trata de uma metodologia visual, também foi aplicado o *Augmented Dickey–Fuller test* (ADCF), para uma visão mais estatística do comportamento da série. Para diferenciação, foi utilizado algumas metodologias para séries não estacionárias, como suavização Logarítmica e Diferenciação por tempo. Logo foi utilizado da Função de autocorrelação (ACF) e Função de autocorrelação Parcial (PACF), para identificação dos pontos a serem utilizados no modelo ARIMA. Ao final foi analisado os resíduos dos modelos gerados. Este passo a passo se enquadra nos passos do Box-Jenkins.

4.1 Série Temporal

Nesta seção será demonstrado 4 princípios importantes para o entendimento dos modelos de séries temporais, Decomposição, Tendências, Sazonalidades e Autocorrelação.

4.1.1 Decomposição

Ehlers (2009) mostra que começa-se a compreender e ter a possibilidade de capturar comportamento e propriedades da série temporal assumindo que X_t seja a série temporal em um tempo t , de forma que:

$$X_t = T_t + C_t + R_t$$

onde T_t é uma componente de tendência, C_t é a sazonalidade e R_t a aleatoriedade, de forma que R_t é a única parte não explicada. Com C_t com uma repetição fixa em s :

$$\dots = C_{t-2s} = C_{t-s} = C_t = C_{t+s} = C_{t+2s} = \dots$$

4.1.2 Séries com Tendências

Em Ehlers (2009), nos diz que não existe uma definição precisa de tendência, mas define como, "uma mudança de longo prazo no nível médio da série". Tendo como problema a definição de longo prazo, por ser relativa ao objeto de estudo.

Temos como uma definição simples de tendência como:

$$X_t = \alpha + \beta t + \varepsilon_t$$

onde α e β são constantes a serem estimadas e ε_t implica em um erro aleatório de média zero. O nível médio da série no tempo t é determinado por $m_t = \alpha + \beta t$. Onde também é chamada por termo de tendência.

4.1.3 Séries Sazonais

Sazonalidade é uma variação C_t que repete ao longo do tempo, sendo a sazonalidade de difícil definição. Entretanto divide em sazonalidade constante e sazonalidade estocástica, onde sazonalidade constante não existe grande variação em t e a sazonalidade estocástica ela demonstra um aumento gradual com o decorrer de t (MORETTIN; TOLOI, 2018).

4.1.4 Autocorrelação

Ainda em Ehlers (2009) uma das principais compreensões a entender para a aplicação de modelos em séries temporais é coeficiente de autocorrelação. A ideia se torna muito parecida com o coeficiente de correlação usual, porém ao invés de medir a correlação entre duas variáveis x e y , aqui iremos tentar observar a correlação entre duas observações da mesma variável, no caso o mesmo x que varia de acordo com diferentes pontos do tempo.

Assim, dadas n observações x_1, \dots, x_n , podemos formar os pares $(x_1, x_2), \dots, (x_{n-1}, x_n)$. Considerando x_1, \dots, x_{n-1} e x_2, \dots, x_n como duas variáveis, o coeficiente de correlação entre as duas é dado por:

$$r_1 = \frac{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)(x_{t+1} - \bar{x}_2)}{\sqrt{\sum_{t=1}^{n-1} (x_t - \bar{x}_1)^2 \sum_{t=1}^{n-1} (x_{t+1} - \bar{x}_2)^2}}$$

Sendo o r_1 o coeficiente de correlação ou coeficiente de correlação serial. Com suas médias sendo

$$\bar{x}_1 = \sum_{t=1}^{n-1} (x_t / (n-1)) \text{ e } \bar{x}_2 = \sum_{t=2}^n (x_t / (n-1))$$

Tendo assim a relação r_1 das correlações entre observações em tempos diferentes.

4.1.4.1 Correlograma

Quando plotamos vários valores k de coeficiente de correlação r_1 , temos o que é chamado de correlograma. Sendo uma das principais ferramentas para analisar os futuros pontos do modelo ARIMA e demonstrar características importantes da série temporal.

4.1.4.2 Interpretações do Correlograma

Por meio do correlograma, de acordo com Ehlers (2009) podemos tentar definir várias características da série, se ela tem correlações aleatórias, correlações negativas, de curto prazo, se a variação é sazonal ou se as observações *outliers* são impactantes ao ponto de enviesar as interpretações.




Figura 1 – Gráfico de Autocorrelação Série Independente

Fonte – Ehlers 2009

No gráfico em observações por tempo na Figura 1, existem 100 observações ao longo do tempo. Pode-se dizer que são independentes, porque não existe uma interferência visível de um ponto em relação ao outro ao longo do tempo, caso contrário geraria uma tendência. Nas observações de autocorrelação por defasagem, o valor de r_1 tende a zero, após a primeira observação, uma forma de verificar que não existe evidência para negar a hipótese de que a série é independente.

Na Figura 2, vemos um exemplo de autocorrelação de Curto-prazo, onde os dados em pequenos períodos de tempo se influenciam, gerando uma pequena tendência, mas depois de mais observações eles se tornam independentes, girando em torno do 0. Ao observar a autocorrelação por defasagem, nota-se que existem valores acima dos limites, mas logo depois se comportam em torno de 0.

Dentre outras situações, um dos principais pontos do correlograma é a identificação da série ser estacionária ou não. De forma que, uma série com tendência bem definida os valores de autocorrelação por defasagem entre os pontos não decairão para zero. Assim, para poder utilizar o correlograma será necessário a transformação de uma série não estacionária para estacionária, como é demonstrado na aplicação do modelo de Box-Jenkins neste trabalho.

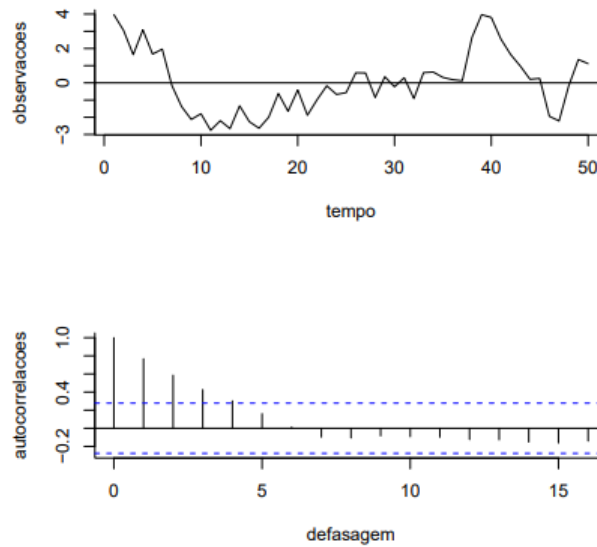


Figura 2 – Gráfico de Autocorrelação Curto-prazo

Fonte – Ehlers 2009

4.2 Representação do modelo ARIMA

Como demonstra Morettin e Tolo (2018) modelo ARIMA divide-se em 3 parâmetros, p , d e q , onde p é o atraso autoregressivo, d ordem de diferenciação e q é o parâmetro de média móvel, representando respectivamente AR, I e MA.

4.2.1 Diferenciação

Como dito em Fracaro (2018), os dados em sua grande parte serão não estacionários, sendo necessária a aplicação de uma transformação nas séries temporais. A base de todas as transformações começa tomando as diferenças por $\Delta y_t = y_t - y_{t-1}$, podendo repetir n vezes, $\Delta^n y_t$, até se atingir a série estacionária. Dependendo da distribuição dos dados, uma diferenciação não é suficiente, sendo necessário a aplicação de uma nova diferenciação, obtendo valor de $d = n$, sendo n a quantidade de diferenciação. Pode-se realizar a suavização da função via logaritmo e aplicar a diferença:


$$\Delta \log y_t = \log y_t - \log y_{t-1}$$

Desta forma é possível reduzir a variância entre os dados obtendo melhor resultado da diferenciação.

4.2.2 Função de Autocorrelação

Como já abordado anteriormente sobre a autocorrelação, temos a função com os valores de autocorrelação, representando a parte q do modelo ARIMA, como demonstrado na Figura 3

Figura 3 – Diagrama de Autocorrelação e Autocorrelação Parcial



Fonte – Autor (2020)

Ao analisar o quadro de Autocorrelação da Figura 3, percebe-se que existe apenas uma reta fora das linhas de controle, esta reta chama-se perna. Considera-se uma perna relevante quando ela se aproxima ou ultrapassa as linhas de controle, de forma a demonstrar o quanto um ponto influenciou o outro a cada defasagem. (TIAO; TSAY, 1985)

4.2.3 Função de Autocorrelação Parcial

A PACF está orientada a classificação do valor p , no caso o que chamam de *Lag*, ou atraso da autoregressão, também sendo encontrada da mesma forma de análise da ACF. Os pontos do eixo y onde os valores vão para 0 em relação ao eixo x . Leva-se em consideração os pontos em que ambos ACF e PACF atingem o ponto 0 após uma variação do gráfico (TIAO; TSAY, 1985).

Analisando a Figura 3, podem existir outros valores de p e q que representem melhor adequação aos modelos. Em Tiao e Tsay (1985), ainda diz que a decisão para os valores de p e q são de grande dificuldades devido a complexidade de análise dos gráficos de ACF e PACF. Desta forma recomenda-se sempre testar outros pontos que vão para 0 e comparar os residuais.

4.3 Box-Jenkins

Box e Jenkins (1976) propôs uma metodologia para criação de um ARIMA, seguindo 3 passos:

- Identificação, é realizado testes estatísticos para compreensão das características das séries
- Estimação, por meio da análise da Auto Correlação e Auto Correlação Parcial, é determinado os pontos utilizados para o modelo ARIMA(p,d,q)
- Diagnóstico, etapa onde se valida os resultados por meio dos resíduos gerados e verificação da validade dos pressupostos.

Desta forma, deve-se repetir as etapas até que o modelo faça sentido ou que se mude o tipo de análise realizada.

4.4 Dickey-Fuller Test

O teste ADCF é um teste de hipótese nula, analisa se a série temporal tem raiz unitária, caso ela tenha raiz unitária é dita não estacionária, caso contrário, é dita estacionária (FRACARO, 2018). Esta análise se torna um dos principais fatores para definir quando deve-se aplicar a diferenciação afim de transformar uma série não estacionária em estacionária. Lembrando que a diferenciação indica o valor do integrador d do modelo ARIMA.

4.4.1 Análise do Resultado do ADCF

O exemplo abaixo demonstra um possível resultado do ADCF,

Figura 4 – Resultado do ADCF Não Estacionário

```
Results of Dickey Fuller Test:
Test Statistic          -0.507952
p-value                 0.890455
#Lags Used              3.000000
Number of Observations Used  22.000000
Critical Value (1%)     -3.769733
Critical Value (5%)     -3.005426
Critical Value (10%)    -2.642501
dtype: float64
```

Fonte – Autor (2020)

Para interpretar a saída com *p – value*, visto em Ferreira e Patino (2015), analisamos se a hipótese nula foi rejeitada para $p – value < 0,05$, caso seja rejeitada temos que a série é estacionária, ou seja, não tem raiz unitária. Caso o *p – value* seja maior que 0,05 então dizemos que ela é não estacionária e precisa de uma transformação matemática para aplicação do modelo ARIMA.

4.5 Análise residual

Como demonstrado em Fracaro (2018), é de grande importância validar o modelo para verificar se este modelo está de acordo com as necessidades iniciais e adequação com a realidade. Dentre as várias formas de validação, neste trabalho foi utilizado a soma das raízes residuais, RSS, que é dado por

$$RSS = \sum_{i=1}^n (Y'_i - Y_i)^2$$

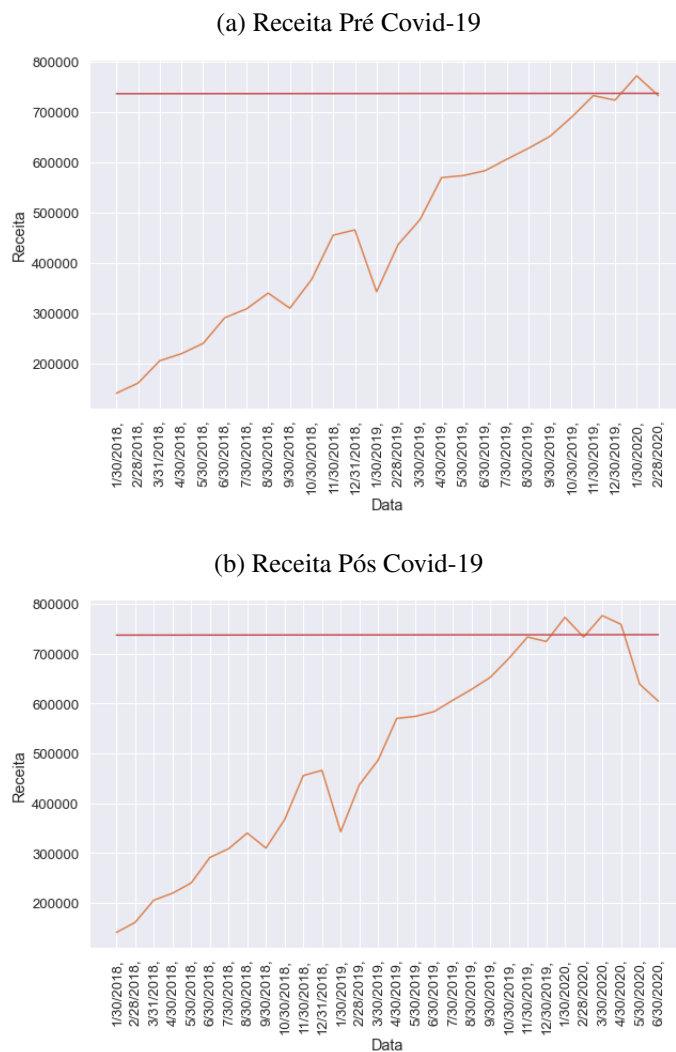
Onde Y'_i é o valor real e Y_i é o valor previsto no modelo, gerando assim a diferença entre cada ponto i gerado. Quanto mais próximo de 0 o valor residual de RSS, melhor os dados de previsão do modelo.

5 Aplicação dos passos de Box-Jenkins

5.1 Levantamento e tratamento dos Dados

Para início do trabalho aplicado, foi realizado o levantamento de dados da receita financeira da empresa. O primeiro grupo de dados foi do período de janeiro de 2018 até fevereiro de 2020. Período pré Covid-19.

Figura 5 – Relação das receitas Antes e Depois do Covid-19



Fonte – Autor (2020)

Com relação ao segundo grupo, foram considerados os dados até junho de 2020, que leva em conta o período de impacto do Covid-19.

Na Figura 5 é possível verificar alguns pontos importantes. No gráfico (b) nota-se a intensidade do impacto da pandemia ao final da curva. Deixando a dúvida sobre a continuidade

da tendência da receita financeira da empresa. Com isso, nasce a necessidade de compreender a previsão em cima dos dois cenários (a) e (b), criando uma possível perspectiva em cima do novo cenário.

Após o levantamento dos dados, tratamento e adequação das estruturas de visualização, foi possível começar os passos da metodologia de Box e Jenkins (1976).

5.2 Identificação das características

Liu e Hudak (1994) diz que, após o primeiro passo de plotagem dos dados para visualização, deve-se começar os processos de análise das características da série temporal. Pela Figura 5, conseguimos notar que em ambas observações existem uma nítida tendência de alta. Ao analisar os períodos de ambos os gráficos, é possível notar que não existe uma sazonalidade relevante, visto que não há um padrão de repetição das variações no gráfico em relação aos mesmos períodos de diferentes anos e existiu uma queda durante o segundo semestre de 2018 devido a Greve dos Caminhoneiros onde paralisou boa parte do mercado. No gráfico (b), é notável a queda existente ao iniciar a pandemia, novamente com uma paralisação do mercado, por ser uma paralisação mais longa, o impacto foi muito maior.

Entretanto, Ehlers (2009) diz que para validar uma tendência de uma série temporal, deve-se verificar se a sua média móvel não se mantém constante com a variação do tempo. Com isso, verificamos os gráficos da Figura 6.

Nota-se uma clara inclinação da curva de média móvel em vermelho com o tempo, porém a curva de desvio padrão, em preto, se mantém lateralizada, demonstrando pouca variação. Assim, confirma-se a existência de uma tendência pela curva da média móvel, mas não podemos afirmar a existência de uma sazonalidade, devido a pequena variação na curva de desvio padrão. Tais análises são puramente visuais. Para ter uma abordagem mais estatística da série, foi aplicado o teste ADCF para verificação real das tendências.

Como é possível notar na Figura 8 do teste do Dick-Fuller, ambos os cenários pré-covid e pós-covid tem um p -value > 0.05 , logo não rejeita a hipótese nula e consequentemente não são estacionários, sendo necessária aplicação da diferenciação para atingir a estacionariedade da série, como já demonstrado no Tópico 4.4.


5.2.1 Aplicação da Diferenciação

Todas as transformações foram aplicadas em ambas observações, mas para objetividade do trabalho, neste tópico será apresentado apenas imagens das observações pós COVID-19.


Antes de aplicar a diferenciação primeiramente foi aplicado logaritmo neperiano nas observações, realizando a suavização da curva, a fim de estabilizar a variância Fracaro (2018). A Figura 8 demonstra a suavização da série temporal por logaritmo, onde a curva azul é a série temporal e a curva vermelha é a média móvel, que serve de orientação para verificação

Figura 6 – Validação da tendência em ambas observações

(a) Média Movel Pós Covid-19



(b) Média Movel Pré COvid-19



Fonte – Autor (2020)

Figura 7 – Análise do resultado do teste ADF

(a) ADF para a base Pré Covid-19

```
Results of Dickey Fuller Test:
Test Statistic      -1.786069
p-value             0.387400
#Lags Used          0.000000
Number of Observations Used  29.000000
Critical Value (1%)  -3.679060
Critical Value (5%)  -2.967882
Critical Value (10%) -2.623158
dtype: float64
```


(b) ADF para a base Pós Covid-19

```
Results of Dickey Fuller Test:
Test Statistic      -0.507952
p-value             0.890455
#Lags Used          3.000000
Number of Observations Used  22.000000
Critical Value (1%)  -3.769733
Critical Value (5%)  -3.005426
Critical Value (10%) -2.642501
dtype: float64
```

Fonte – Autor (2020)

da tendência. Em comparação da Figura 8 com a Figura 6 (a), é possível notar uma redução na inclinação da curva da Figura 8 devido a aplicação do logaritmo.

Figura 8 – Transformação dos dados por logaritmo



Fonte – Autor (2020)


Constata-se na Figura 9 (a) a transformação de diferenças entre curvas, uma forma de diferenciação, onde pegou-se a curva suavizada pelo logaritmo e diferenciou-se com sua média móvel. Demonstra um resultado mais visível de mudança de tendência. Entretanto, pelo teste ADCF é possível verificar que ainda não se atingiu o necessário para estacionariedade da série. Porque o valor p – *value* na Figura 9 (b) ainda está muito acima de 0,05.

Além do resultado do p – *value* nota-se que os valores críticos são muito distantes do valor de teste estatístico e que ainda existe uma tendência decrescente após a transformação, demonstrando que esta transformação foi muito ineficiente.

Na Figura 10 (a) foi aplicado a diferenciação por deslocamento dos períodos de observações, analisando o resultado na Figura 10 (b) foi a única a ter o p – *value* < 0.05 , finalmente transformando a série em estacionária. Para as observações dos dados pré COVID-19 também foi utilizada a mesma diferenciação. Lembrando que não foram aplicadas transformações em seguidas, o que ocasionaria na mudança de ordem. Mas formas diferentes de diferenciação, a primeira técnica foi diferenciar os pontos da função dos pontos da média móvel, depois a segunda técnica utilizada foi diferença entre a mesma função, com os pontos deslocados no tempo.

Desta forma, a série atingiu a estacionariedade e foi possível realizar as análises de autocorrelação e autocorrelação parcial.

Figura 9 – Teste para Diferença entre médias móveis



(b) ADF para Médias Móveis


```

Results of Dickey Fuller Test:
Test Statistic           0.999167
p-value                  0.994257
#Lags Used               2.000000
Number of Observations Used  16.000000
Critical Value (1%)      -3.924019
Critical Value (5%)      -3.068498
Critical Value (10%)     -2.673893
dtype: float64
    
```

Fonte – Autor (2020)

Figura 10 – Diferença por deslocamento dos períodos de Tempo

(a) Diferença entre Valor Deslocado



(b) ADF para Valor Deslocado

```

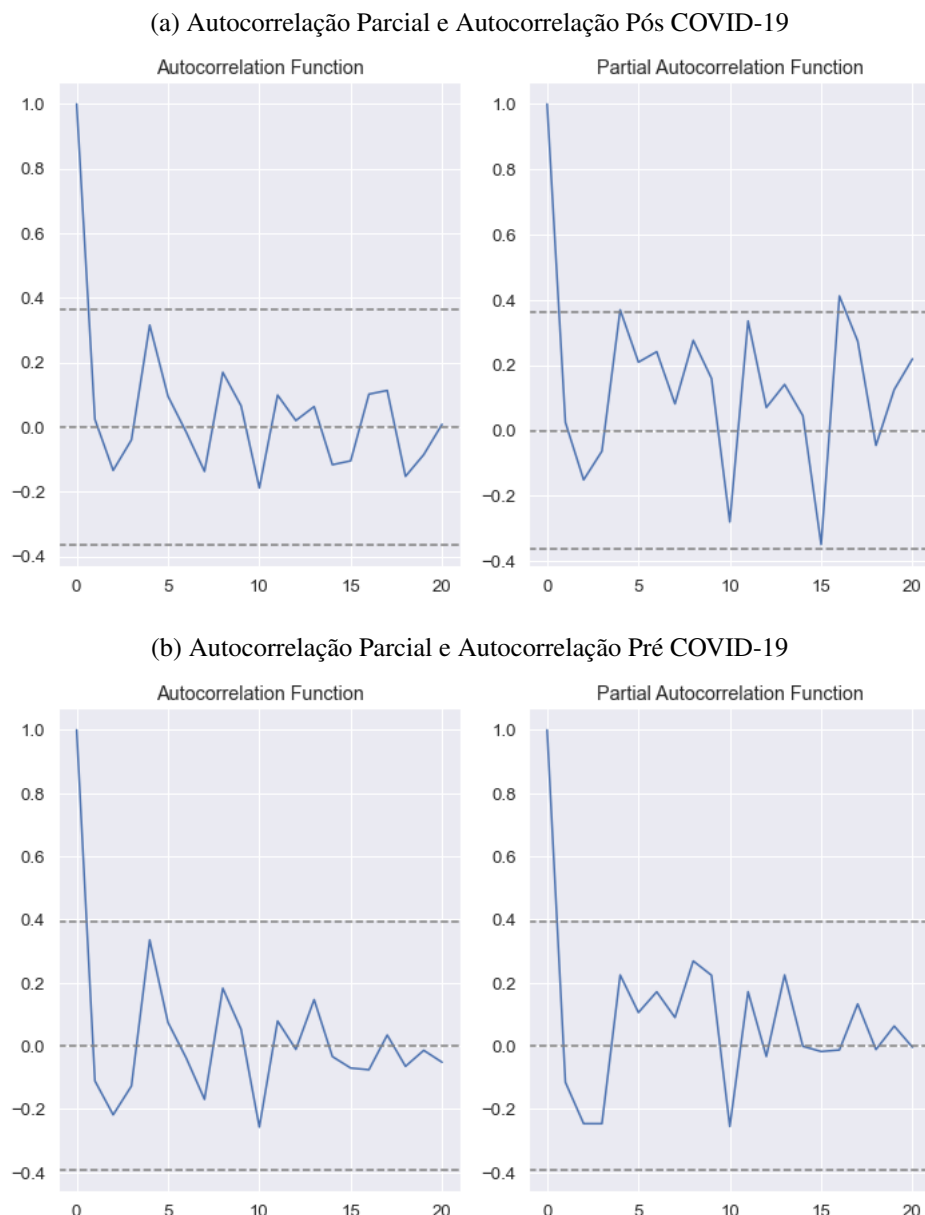
Results of Dickey Fuller Test:
Test Statistic          -4.944823
p-value                 0.000029
#Lags Used              0.000000
Number of Observations Used  28.000000
Critical Value (1%)     -3.688926
Critical Value (5%)    -2.971989
Critical Value (10%)   -2.625296
dtype: float64
    
```

Fonte – Autor (2020)

5.3 Estimação dos Parâmetros ARIMA

Como já demonstrado no Tópico 4, os parâmetros p, d, q determinam o modelo ARIMA, após realizar a transformação das séries em estacionárias é possível obter informações das análises de ACF e PACF, encontrando os valores de p e q . Aplicando as funções de autocorrelação e autocorrelação parcial, obtém-se os 4 gráficos na Figura 11, para os dois grupos de observações.

Figura 11 – Comparação dos gráficos de Autocorrelação e Autocorrelação Parcial



Fonte – Autor (2020)

É possível notar onde o eixo Y, valor de correlação, encontra com zero em ambos os gráficos, encontrando p e q para o ajuste do modelo ARIMA (TIAO; TSAY, 1985). Como não existe uma defasagem com um ponto de correlação relevante após o ponto 2 no eixo X, visto que


após a primeira perna os valores seguintes não ultrapassam a linha de controle em pontilhado, foi aplicado o modelo nas configurações (2,1,2), sendo p e $q = 2$ e $d = 1$ por ter atingido a estacionariedade com uma diferenciação. Foi testado outros valores entre 0 e 5, entretanto não deram residuais melhores na fase de Diagnóstico do que as configurações (2,1,2).

5.4 Diagnóstico

Em Box e Jenkins (1976), o Diagnóstico é a etapa onde avalia-se a estrutura e os resultados do modelo criado, de forma a testar se as configurações escolhidas fazem sentido ao analisar dados previstos em relação aos dados utilizados como base. Assim, foi avaliada a construção dos parâmetros para o ARIMA comparando o resultado da previsão com a base de observação, utilizando a diferença da raiz da soma dos quadrados (RSS), para avaliação dos residuais, quanto mais próximo de 0, tem-se um indicativo de um modelo ajustado.

Ao analisar a Figura 12 para ambos os casos, onde a linha em azul são os dados da série histórica no formato estacionário e em vermelho os dados previstos do ARIMA para o mesmo período, nota-se que o RSS de ambos os grupos foram próximos de 0. Podendo concluir que os modelos são satisfatórios e podem ser utilizados para previsão de resultados futuros.

Figura 12 – Comparação dos risudais dos modelos ARIMA



Fonte – Autor (2020)

6 Resultados e discussões

Antes de analisar os resultados, existem algumas perspectivas que são importantes de serem citadas, até então no ano de 2020 a expectativa da empresa era manter o ritmo de crescimento histórico desde 2018, dobrando o resultado financeiro ao final do ano de 2020. Entretanto com o advento do COVID-19, o planejamento teve de ser ajustado.

Desta forma, é possível notar na Figura 13, o resultado do modelo para as observações pré Covid-19.





Figura 13 – Modelo ARIMA(2,1,2) Pré Covid

Fonte – Autor

Nota-se na Figura 13, onde Eixo Y é o valor de receita em logaritmo e Eixo X mês sequencial, que a previsão seguiu a tendência histórica das receitas. Na figura 14, a curva de densidade dos valores residuais entre o modelo previsto e os dados históricos, demonstra que a média da diferença dos resultados se concentra em 0, ou seja, além do resíduo ser baixo, não teve muita variação.


Dado o primeiro cenário, foi analisado os resultados do segundo modelo, com os dados após a pandemia. Seguindo a mesma estrutura de análise do primeiro cenário, a primeira parte foi visualizar os dados da relação da previsão com os dados reais.

Figura 14 – Distribuição de resíduos Pré-Covid



Fonte – Autor (2020)

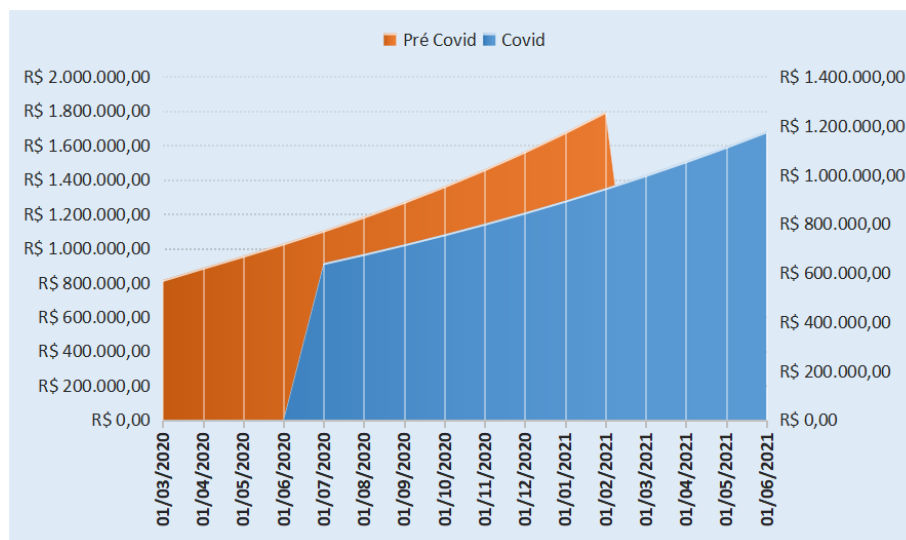
Figura 15 – Modelo ARIMA(2,1,2) Pós Covid-19



Fonte – Autor (2020)

O gráfico de previsão na Figura 15, em vermelho a receita original e azul o previsto, ficou ajustado a realidade como no primeiro caso Pré Covid-19, demonstrado pela análise de RSS na Figura 12 (b). Apesar da queda dos resultados financeiros nos períodos de Covid-19, a Figura 15 demonstrou uma tendência de crescimento nos meses seguintes com os dados previstos. Para ter uma visualização comparativa entre os cenários foi criado um gráfico apenas com os resultados previsto de ambos os modelos.

Figura 16 – Relação de previsão de receitas dos modelos



Fonte – Autor (2020)

Na Figura 16, gráfico dos dados previstos Pré e Pós Covid-19, nota-se que a recuperação no longo prazo ainda segue uma tendência de alta. Em comparação entre os dois momentos, temos que a faixa de R\$1 milhão seria alcançada, no cenário pré Covid-19, no 2º trimestre de 2020. E com a nova realidade do Covid-19, tivemos o deslocamento de 1 ano, com a previsão demonstrando alcançar R\$1 milhão de receita no 2º trimestre de 2021. Ou seja, com 4 meses de queda, existiu um deslocamento de 1 ano em relação a um mesmo ponto da receita mensal.

Mintzberg, Ahlstrand e Lampel (2000) diz que o objetivo em modelar previsões de dados não é acertar exatamente o dia ou o valor de uma receita, mas ter uma noção de como vai ser o comportamento das observações no futuro, dado que não existe precisão em previsões de longo prazo. Desta forma, além de ter uma visualização de como os resultados se modificaram, a empresa ao atualizar o modelo com novos dados, pode medir o quão rápido consegue retornar a realidade do pré Covid-19 e reduzir o espaçamento de 1 ano nas receitas.

7 Conclusão e trabalhos futuros

O mundo das empresas de tecnologia é composto por alta imprevisibilidade, sendo uma das características principais desse nicho. No Brasil ainda é muito recente o desenvolvimento das chamadas *startups*, tendo grande crescimento desde 2015. No âmbito de planejamento estratégico, Mintzberg, Ahlstrand e Lampel (2000) diz que é de extrema importância para empresa ter ferramentas que auxiliem visões futuras, sejam elas em previsões de demanda, análises macroeconômicas ou como no trabalho apresentado, a própria receita da empresa. Porém, as previsões de modelos não devem ser levadas como uma direção, mas sim como referência a tomada de decisão (AZEVEDO; SILVA; GATSIOS, 2015).

Essa visão de comportamento das séries temporais, pode trazer uma vantagem estratégica para essas empresas que vivem em um universo de alta imprevisibilidade. Tendo maior arcabouço para planejar melhor a alocação de recursos.

O mundo sempre terá eventos que não são possíveis de serem previstos, seja uma Greve dos Caminhoneiros ou uma Pandemia. Mas com as ferramentas matemáticas adequadas, aprendidas tanto no curso de Engenharia como em outras ciências exatas, é possível trazer mais controle e segurança para os tomadores de decisão.

Como visto neste trabalho, sem a utilização de tais modelos, a empresa teria como segurança apenas a visão e conhecimento tácito do corpo executivo para tomada de decisão, tendo um menor aproveitamento dos recursos. Ao analisar os resultados, foi possível verificar que a Pandemia trouxe um impacto muito mais severo que a Greve dos Caminhoneiros, com uma queda de 4 meses deslocando o crescimento de receita em quase 1 ano em relação ao que deveria ser alcançado no mesmo período, caso não existisse o impactado da pandemia.

Tendo em vista essa informação, a empresa pode protelar alguns investimentos, focando em melhorias operacionais, estratégias para retenção de receita ou reduzir alavancagem. Algo imprescindível para uma empresa de alto risco e recursos limitados. Podendo também, utilizar o modelo pós Covid-19 como uma referência, para verificar o formato da curva de recuperação em relação a previsão do pré Covid-19.

Para futuros trabalhos existe a possibilidade de explorar várias novas pesquisas. Dentre elas a previsão de cenários aplicando modelos probabilísticos como em Neto, Moura e Forte (2013), com a utilização do modelo de Monte Carlo. Ou como citado em Azevedo, Silva e Gatsios (2015), modelos de variância condicional como ARCH, que em conjunto com ARIMA podem estruturar séries temporais com situações de maior volatilidade. Até mesmo revisão do atual trabalho com a atualização dos dados após a pandemia, por meio da comparação dos dados previstos com o cenário real.

O mundo das *startups* no Brasil já é uma realidade, sendo uma grande oportunidade para conexão do meio acadêmico com o mercado. De forma que os acadêmicos tem liberdade para aplicar novas ideias e explorar áreas que nem sempre são relacionadas á rotina de trabalho.

Referências

- AZEVEDO, R. R. D.; SILVA, J. M. D.; GATSIOS, R. C. Comparação de modelos de previsão de série temporal com base no icms estadual. *XV Congresso USP Contabilidade e Controladoria no século XXI*, v. 1, n. 1, 2015.
- BOX, G.; JENKINS, G. *Time series analysis forecasting and control*. Oakland: Holden Day Inc., 1976.
- BRITO, F. G. de. Aplicação do modelo arima na previsão de atendimento em pontos de atenção com alta demanda de rede de assistência à saúde do município de monte carmelô, mg. *Universidade Federal de Uberlândia*, 2019.
- CARRILO, A. F. Crescimento das startups. *Abstartups*, 2020. Disponível em: <<https://abstartups.com.br/crescimento-das-startups/>>. Acesso em: 28 jul. 2020.
- DIGITAIS, R. Os impactos da covid-19 e os passos para retomada. 2020. Disponível em: <https://rd-marketing-objects.s3.amazonaws.com/panorama-pmes-covid19/Panorama_PMEs-resumo.pdf>. Acesso em: 28 jul. 2020.
- EHLERS, R. S. Análises de séries temporais. Universidade Federal do Paraná - Departamento de Estatística, v. 5, 2009.
- FERREIRA, J. C.; PATINO, C. M. O que realmente significa valor-p? *J Bras Pneumol*, v. 1, n. 1, 2015.
- FRACARO, N. Estacionaridade das séries temporais do modelo matemático arimax de propulsores eletromecânicos. Universidade Regional do Noroeste do Estado do Rio Grande do Sul - UNIJUÍ, 2018.
- GIL, A. C. *Como elaborar projetos de pesquisa*. [S.l.]: Atlas, 2002. v. 4.
- HAMILTON, J. D. *Time Series Analysis*. [S.l.]: Princeton University Press, 1994. v. 10.
- LIU, L.-M.; HUDAK, G. B. *Forecasting and time series analysis using the sca statistical system*. Scientific Computing Associates, 1994.
- LOSEKANN, L. O impacto da covid-19 no mercado brasileiro de combustíveis. *Brasil Energial*, 2020. Disponível em: <<https://petroleohoje.editorabrasilenergia.com.br/impacto-da-covid-19-no-mercado-brasileiro-de-combustiveis/>>. Acesso em: 28 jul. 2020.
- MARCONI, M. de A.; LAKATOS, E. *Metodologia do trabalho científico: procedimentos básicos, pesquisa bibliografia, projeto e relatório, publicações e trabalhos científicos*. [S.l.]: Atlas, 2006. v. 6.
- MATOS, S. Boletim macro junho 2018. *FGV IBRE*, 2018. Disponível em: <https://portalibre.fgv.br/sites/default/files/2020-02/boletimmacroibre_1806.pdf>. Acesso em: 28 jul. 2020.
- MINTZBERG, H.; AHLSTRAND, B.; LAMPEL, J. *Safári de Estratégia*. [S.l.]: Bookman, 2000.

- MORETTIN, P. A.; TOLOI, C. M. C. *Análise de Séries Temporais*. [S.l.]: Edgard Blucher Ltda., 2018.
- NETO, J. F. C.; MOURA, H. J. de; FORTE, S. H. A. C. Modelo prático de previsão de fluxo de caixa operacional para empresas comerciais considerando os efeitos do risco, através do método de monte carlo. *Revista Eletrônica de Administração*, v. 8, n. 3, 2013.
- PENIDO, R. M. e M. Como o vale do silício se tornou o vale do silício? *Endeavor*, 2014.
- RIES, E. *The Lean Startup*. [S.l.]: Crown Publishing Group, 2011. 26–210 p.
- TIAO, G.; TSAY, R. A canonical correlation approach to modeling multivariate time series. *Proceedings of the Business and Economic Statistics*, American Statistical Association, p. 112–120, 1985.
- TURRIONI, J. B.; MELLO, C. H. P. Metodologia de pesquisa em engenharia de produção. Universidade Federal de Itajubá - UNIFEI, 2012.