

UNIVERSIDADE FEDERAL DO PARANÁ

RICARDO SERPE MACHOSKI

MODELAGEM DE SÉRIES TEMPORAIS DO PREÇO DA GASOLINA NO BRASIL
PARA ANÁLISE: COMPARAÇÃO ENTRE MÉTODOS DE PREVISÃO E ANÁLISE
CAUSAL DAS OSCILAÇÕES

CURITIBA

2024

Ricardo Serpe Machoski

MODELAGEM DE SÉRIES TEMPORAIS DO PREÇO DA GASOLINA NO BRASIL
PARA ANÁLISE: COMPARAÇÃO ENTRE MÉTODOS DE PREVISÃO E ANÁLISE
CAUSAL DAS OSCILAÇÕES

Trabalho de Conclusão de Curso apresentado ao curso de Graduação em Gestão da Informação, Setor de Ciências Sociais Aplicadas, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Bacharel em Gestão da Informação.

Orientador: Prof. Dr. Luciano Heitor Gallegos Marin.

CURITIBA

2024

Dedico este Trabalho de Conclusão de Curso a minha querida esposa Daphne Louise Carol de Oliveira Machoski, agradeço por seu amor, apoio e compreensão incondicional ao longo desta jornada.

RESUMO

Desde o século passado, os combustíveis têm sido fundamentais para o progresso das sociedades, fazendo com que variações em seus preços impactem diretamente o bem-estar das nações. Assim, com o objetivo de conter a inflação local, faz-se necessário constantes adequações nas estratégias políticas governamentais e na precificação estabelecida pelas petrolíferas. Entretanto, para que tais mudanças sejam eficazes, é importante utilizar modelos de previsão que corroboram a detecção de incertezas e oportunidades no cenário atual. Nesse sentido, o propósito central deste trabalho é determinar qual modelo de previsão, com abordagem autorregressiva e de médias móveis, é mais assertivo para a previsão de séries temporais e análise das oscilações no preço da gasolina no Brasil. Para atender a este propósito, utilizou-se uma metodologia constituída de quatro etapas complementares: (1) Coleta de dados para obter o preço de combustíveis no Brasil; (2) Tratamento dos dados para gerar o preço médio da gasolina no país ao longo da última década; (3) Desenvolvimento de modelos de previsão para 6, 12 e 18 meses do preço do combustível, com diferentes abordagens e bases históricas; (4) Definição dos principais períodos de oscilação do preço do combustível e condução de uma análise causal dos seus fatores impactantes. Como resultado, verifica-se que o método mais assertivo para prever o preço da gasolina no Brasil a curto prazo é o Autorregressivo (AR), enquanto o de Médias Móveis (MA) é mais bem ajustado para previsões de médio e longo prazo. Ademais, compreende-se que os principais fatores externos de impacto na oscilação da série é o desequilíbrio no mercado ocasionado por guerras, crises econômicas e pandemias; assim como também a política de precificação de petrolíferas, alterações de regulamentações e também estratégias políticas. Dessa maneira, este trabalho aprofunda conhecimentos de metodologias de previsão sobre a precificação da gasolina no Brasil, oferecendo auxílio na formulação de estratégias econômicas para o planejamento e tomada de decisão de investidores, empresas do setor e consumidores do produto.

Palavras-chave: séries temporais; modelos de previsão; preço da gasolina; modelos autorregressivos; modelos de médias móveis.

ABSTRACT

Since the last century, fuels have been fundamental to the progress of societies, causing variations in their prices to directly impact the well-being of nations. Thus, in order to contain local inflation, it is necessary to make constant adjustments in the strategic government policies and in the pricing established by the oil companies. However, for such changes to be effective, it is important to use forecasting models that corroborate the detection of uncertainties and opportunities in the current scenario. In this sense, the main purpose of this work is to determine which prediction model, with autoregressive and/or moving averages approaches, is more assertive for the prediction of time series and analysis of fluctuations in the price of gasoline in Brazil. To meet this purpose, a methodology consisting of four complementary steps was used: (1) Data collection to obtain the price of fuels in Brazil; (2) Data treatment to generate the average price of gasoline in the country over the last decade; (3) Development of a 6-, 12- and 18-months fuel price forecasting models, with different approaches and historical bases; (4) Definition of the main periods of gasoline price fluctuation and conduction of a causal analysis of their impacting factors. As a result, it is understood that the most assertive method to predict the price of gasoline in Brazil in the short term is the Autoregressive (AR) one, while the Moving Averages (MA) is better adjusted for medium and long-term forecasts. In addition, it is stated that the main external factors impacting the fluctuations in the series are the imbalance in the market caused by wars, economic crises and pandemics, as well as the pricing policy of oil companies, changes in local regulations and political strategies. In this way, this work deepens knowledge of forecasting methodologies on gasoline pricing in Brazil, offering assistance in the formulation of economic strategies for the planning and decision-making of investors, companies in the sector and consumers of the product.

Keywords: time series; forecasting model; gasoline prices; autoregressive models; moving average models.

LISTA DE FIGURAS

FIGURA 1 - EXEMPLO DE DECOMPOSIÇÃO ADITIVA DE SÉRIE TEMPORAL....	24
FIGURA 2 - DESENHO GERAL DE PESQUISA.....	29
FIGURA 3 - DESENHO DE PESQUISA: ETAPA (A) COLETA DE DADOS	30
FIGURA 4 - DESENHO DE PESQUISA: ETAPA (B) TRATAMENTO DE DADOS ...	30
FIGURA 5 - DESENHO DE PESQUISA: ETAPA (C) MODELOS DE PREDIÇÃO....	32
FIGURA 6 - DESENHO DE PESQUISA:ETAPA (D) ANÁLISE CAUSAL.....	34
FIGURA 7 - SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL	36
FIGURA 8 - ALGORITMO EM PYTHON PARA A DECOMPOSIÇÃO ADIVITA DA SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL	37
FIGURA 9 - DECOMPOSIÇÃO DA SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL	37
FIGURA 10 - PERÍODO PARA TREINO DE PREVISÃO DE 6 MESES DO PREÇO DA GASOLINA NO BRASIL.....	43
FIGURA 11 - TESTE ESTACIONÁRIO PARA A BASE TREINO – PREVISÃO 6 MESES	44
FIGURA 12 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR MÉDIAS MÓVEIS	44
FIGURA 13 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 6 MESES (JAN'24-JUN'24).....	45
FIGURA 14 - PERÍODO PARA TREINO DE PREVISÃO DE 12 MESES DO PREÇO DA GASOLINA NO BRASIL.....	46
FIGURA 15 - TESTE ESTACIONÁRIO E DIFERENCIAÇÃO PARA A BASE TREINO – PREVISÃO 12 MESES	47
FIGURA 16 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR AUTORREGRESSÃO	48
FIGURA 17 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 12 MESES (JAN'24-DEZ'24)	49
FIGURA 18 - PERÍODO PARA TREINO DE PREVISÃO DE 18 MESES DO PREÇO DA GASOLINA NO BRASIL.....	50
FIGURA 19 - TESTE ESTACIONÁRIO E DIFERENCIAÇÃO PARA A BASE TREINO – PREVISÃO 18 MESES	51

FIGURA 20 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR AUTORREGRESSÃO	52
FIGURA 21 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 18 MESES (JAN'24-JUN'25).....	53
FIGURA 22 - ALGORITMO AUTOARIMA PARA DETECTAR OSCILAÇÕES NA SÉRIE TEMPORAL.....	54
FIGURA 23 - PRINCIPAIS PERÍODOS DE OSCILAÇÃO POSITIVA E NEGATIVA NA SÉRIE TEMPORAL (ILUSTRAÇÃO)	55
FIGURA 24 - RESUMO GRÁFICO DOS PRINCIPAIS PROCESSOS E RESULTADOS.....	58

LISTA DE TABELAS

TABELA 1 - PERÍODO HISTÓRICO BASE PARA ANÁLISE DOS MODELOS PREDITIVOS.....	32
TABELA 2 - PERÍODO DA SÉRIE TEMPORAL UTILIZADO PARA TREINO E TESTE PARA CADA ABORDAGEM DE PREDIÇÃO REALIZADA.....	33
TABELA 3 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO DE AUTORREGRESSÃO.....	39
TABELA 4 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO DE MÉDIAS MÓVEIS	39
TABELA 5 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTORREGRESSIVO DE MÉDIAS MÓVEIS	40
TABELA 6 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTORREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS	40
TABELA 7 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTORREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS SAZONAIS	41
TABELA 8 - RESULTADO DOS ERROS QUADRÁTICOS MÉDIOS DE CADA MODELO POR PERÍODO TESTE E TREINO AVALIADO	42
TABELA 9 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 6 MESES	45
TABELA 10 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 12 MESES.....	48
TABELA 11 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 18 MESES.....	52
TABELA 12 - PRINCIPAIS PERÍODOS DE OSCILAÇÃO POSITIVA E NEGATIVA NA SÉRIE TEMPORAL	55

LISTA DE ABREVIATURAS OU SIGLAS

ADF	- Teste para estacionariedade de Dickley-Fuller Aumentado
AIC	- Critério de Informação de Aikake
ANP	- Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
AR	- Modelo Autorregressivo
ARCH	- Heteroscedasticidade Condicional Autorregressiva
ARFIMA	- Média Móvel Integrada Fracionada
ARIMA	- Modelo Autorregressivo Integrado de Médias Móveis
ARMA	- Modelo Autorregressivo de Médias Móveis
EQM	- Erro quadrático médio
FAC	- Funções de Autocorrelação
FACP	- Funções de Autocorrelação Parcial
GARCH	- Heteroscedasticidade Condicional Autorregressiva Generalizada
GLP	- Gás Liquefeito de Petróleo
GNV	- Gás Natural Veicular
IPCA	- Índice Nacional de Preços ao Consumidor Amplo
KPPS	- Teste para estacionariedade de Kwiatkowski–Phillips–Schmidt–Shin
MA	- Modelo de Médias Móveis
PP	- Teste para estacionariedade de Phillips-Perron
PPI	- Preços de Paridade de Importação
SARIMA	- Modelo Autorregressivo de Médias Móveis Sazonais
SC	- Critério de Schwarz
ST	- Séries Temporais
TARCH	- Heteroscedasticidade Condicional Autorregressiva
VEC	- Modelo de Autorregressão Vetorial com Correção de Erro

SUMÁRIO

1	INTRODUÇÃO	16
1.1	PROBLEMA	18
1.2	OBJETIVOS	18
1.2.1	Objetivo geral	19
1.2.2	Objetivos específicos.....	19
1.3	JUSTIFICATIVA	19
2	REVISÃO DE LITERATURA	21
2.1	GASOLINA: RELEVÂNCIA E PRECIFICAÇÃO NO BRASIL	21
2.2	ANÁLISE DE SÉRIES TEMPORAIS (ST)	23
2.3	MÉTODO DE PREVISÃO AUTORREGRESSIVOS E DE MÉDIAS MÓVEIS COM SÉRIES TEMPORAIS	25
2.3.1	Modelo Autorregressivo (AR)	25
2.3.2	Modelo de Médias Móveis (MA)	26
2.3.3	Modelo Autorregressivo de Médias Móveis (ARMA)	26
2.3.4	Modelo Autorregressivo Integrado de Médias Móveis (ARIMA)	27
2.3.5	Modelo Autorregressivo Integrado de Médias Móveis Sazonais (SARIMA)	27
3	MATERIAL E MÉTODOS	29
3.1	DESENHO GERAL DE PESQUISA	29
3.1.1	Coleta de Dados.....	29
3.1.2	Tratamento de Dados.....	30
3.1.3	Modelos de Predição.....	31
3.1.4	Análise Causal de Oscilações	34
4	APRESENTAÇÃO DOS RESULTADOS	36
4.1	CARACTERÍSTICAS DA SÉRIE TEMPORAL DE PREÇO DA GASOLINA NO BRASIL	36
4.2	MODELOS E RESULTADOS DE PREVISÕES	38
4.2.1	Modelos.....	38
4.2.2	Previsões.....	43
4.2.2.1	Previsão preço médio da gasolina no Brasil – 6 meses	43
4.2.2.2	Previsão preço médio da gasolina no Brasil – 12 meses	46
4.2.2.3	Previsão preço médio da gasolina no Brasil – 18 meses	49

4.3	ELEMENTOS EXTERNOS DE IMPACTO NA PRECIFICAÇÃO DA GASOLINA NO BRASIL	54
4.3.1	Elementos externos de impacto na redução do preço da gasolina no Brasil .	56
4.3.2	Elementos externos de impacto no aumento do preço da gasolina no Brasil	57
5	CONSIDERAÇÕES FINAIS	58
	REFERÊNCIAS.....	61

1 INTRODUÇÃO

Desde o século passado os combustíveis possuem papel crítico para o desenvolvimento das sociedades, fornecendo a possibilidade de locomoção de bens e pessoas (PRAUCHNER ET AL., 2022). Como consequência desta demanda, principalmente de combustíveis provenientes do petróleo, seus preços e oscilações impactam diretamente no bem-estar dos países, fomentando inflações e restringindo o poder de compra dos cidadãos (FONSECA, 2023).

No Brasil, a gasolina é o combustível de maior consumo no mercado e estima-se que a sua demanda irá aumentar em mais de 3% durante este ano (CNN, 2023), fazendo com que políticas governamentais e a precificação de petrolíferas sejam readequadas para suprir a demanda, evitando perda de lucros e redução da qualidade financeira da população (AGÊNCIA SENADO, 2023; MARJOTTA-MAISTRO E BARROS, 2023; PUCRS, 2023; TOMAZELLI, GARCIA E BRANT, 2023). Entretanto, para que tais contramedidas sejam eficientes, devem-se utilizar ferramentas e processos que corroboram a detecção de incertezas e oportunidades no cenário atual (BRESSAN, 2004).

As abordagens comumente utilizadas para a previsão de séries temporais são técnicas de *Machine Learning* (Aprendizado de Máquina, e português) e modelos estáticos, pois possuem abordagem matemática para o desenvolvimento de análises causais sobre oscilações históricas do preço de insumos, assim como também realizam previsões futuras para a compreensão do comportamento do mercado de bens (BANDURA ET AL., 2019; BRESSAN, 2004; CAMPOS, 2008; MAKRIDAKIS ET AL., 1982; OLIVEIRA E CISÍSTOMO, 2015; SATO, 2013; XAVIER, 2016).

É possível encontrar na literatura diversos estudos de comparação entre métodos, com o objetivo de determinar suas eficácias na previsão do preço de *commodities*¹ e outros alimentos. Por exemplo, o artigo de Tibulo e Tibulo (2014) analisa o preço do milho, *commodity* de grande importância no Rio Grande do Sul, Brasil; fazendo um comparativo entre o modelo Autorregressivo Integrado de Média Móvel (ARIMA) e o Alisamento Exponencial de Holt-Winters.

¹ Bem em estado bruto de origem agropecuária, mineral ou vegetal, com baixo valor agregado e produzido em escala (Oxford Languages, 2024).

Ademais, o artigo de Arêdes e Pereira (2008) tem foco no planejamento de produção e comercialização do trigo no estado do Paraná, Brasil; avaliando a potencialidade de previsão dos modelos ARIMA, SARIMA (ARIMA com componente sazonal), Heteroscedasticidade Condicional Autorregressiva (ARCH), Heteroscedasticidade Condicional Autorregressiva Generalizada (GARCH) e Limite de Heteroscedasticidade Condicional Autorregressiva (TARCH). Além disto, os autores Santos e Chaucoski (2022) comparam os modelos SARIMA e PROPHET (predição de modelos univariados) para a previsão do preço de ovos no Paraná, Brasil.

Para produtos provenientes de *commodities* de energia, é possível detectar que há um interesse crescente nos últimos anos sobre a previsão da demanda de combustíveis. Como por exemplo, o estudo de Santos Junior (2018) compara os modelos ARIMA e de Regressão Linear Múltipla; e o artigo de Tavares et al. (2021) analisa os modelos de Média Móvel Simples, Média Móvel Ponderada, Suavização Exponencial Simples, Método de Holt, Método de Holt-Winters Aditivo e Multiplicativo.

Os estudos mais recentes de previsão de preço com a gasolina utilizam modelos de redes neurais (ARAÚJO E NETO, 2016), Modelo de Autorregressão Vetorial com Correção de Erro (VEC) (DIEHL, 2012) e Regressão Linear Múltipla (FERNANDES E CARVALHO, 2022). Nos últimos cinco anos, muitos estudos sobre a previsão do preço de combustíveis no Brasil utilizando séries temporais têm focado em combustíveis alternativos, em vez da gasolina. Por exemplo, o estudo de Turqueti (2022) compara a eficiência do modelo ARIMA e de redes neurais para previsão do preço do óleo diesel na região sudeste do Brasil; e o artigo de Brito et al. (2018) que avalia a previsão do preço do etanol no Brasil, comparando os modelos ARIMA, Média Móvel Integrada Fracionada (ARFIMA) e o Exponencial Suavizado.

Dessa maneira, o presente trabalho tem o objetivo de integrar na literatura dados recentes sobre a precificação da gasolina no Brasil, abrangendo períodos de 6, 12 e 18 meses de previsão, com a utilização dos modelos Autorregressivo (AR), Médias Móveis (MA), Autorregressivo de Médias Móveis (ARMA), Autorregressivo Integrado de Médias Móveis (ARIMA) e Autorregressivo Integrado de Médias Móveis Sazonais (SARIMA).

Além do mais, devido ao fato de a precificação de bens de consumo ser impactada por fatores externos, como a política governamental local, o mercado global, crises econômicas e pandemias (FILHO, MARCACINI E REZENDE, 2021); busca-se adicionar uma análise causal das principais oscilações no preço da gasolina nos últimos 10 anos, detectadas por meio do modelo mais acurado desenvolvido anteriormente. Dessa forma, o presente trabalho corrobora o planejamento e tomada de decisão de investidores, empresas do setor e consumidores do produto, oferecendo auxílio na formulação de estratégias econômicas.

A seguir, apresentam-se o problema e objetivos de pesquisa, assim como também a justificativa para o desenvolvimento deste trabalho. Ademais, as sessões posteriores estão divididas da seguinte forma: (2) Referencial Teórico, englobando a precificação da gasolina e seus impactos sociais e econômicos, o conceito e utilização de Séries Temporais e os cinco modelos de previsão utilizados no desenvolvimento do trabalho; (3) Metodologia, onde apresenta-se o procedimento definido para responder o objetivo de pesquisa; (4) Resultados, expõem-se os modelos desenvolvidos, seus comparativos e as principais oscilações no preço da gasolina na última década; e, por fim, (5) Considerações finais, onde apresentam-se as principais conclusões, respondendo à pergunta central de pesquisa; assim como também avalia-se a metodologia utilizada, sugerindo vias para futuras pesquisas.

1.1 PROBLEMA

Diante da introdução acima colocada, pode-se propor a seguinte pergunta: qual modelo de previsão, com abordagem autorregressiva e de médias móveis, é mais assertivo para a previsão de séries temporais e análise das oscilações do preço da gasolina no Brasil?

1.2 OBJETIVOS

Neste tópico são abordados tanto os objetivos gerais quanto os específicos de forma a atender à problemática da pesquisa e em conformidade com o projeto proposto.

1.2.1 Objetivo geral

Identificar o modelo mais assertivo para previsão de séries temporais sobre o preço da gasolina no Brasil, visando analisar suas oscilações detectadas pela abordagem mais assertiva.

1.2.2 Objetivos específicos

O objetivo-geral será alcançado a partir da conclusão dos seis objetivos específicos:

- a) Conduzir uma Revisão da Literatura sobre os modelos de previsão de preços com séries temporais, abrangendo modelos autorregressivos e de médias móveis, correlacionados com combustíveis;
- b) Construir a série temporal do preço da gasolina e determinar suas características por meio do processo de decomposição;
- c) Desenvolver modelos de previsão para o preço da gasolina com 5 abordagens diferentes, envolvendo os modelos Autorregressivo (AR), Médias Móveis (MA), Autorregressivo de Médias Móveis (ARMA), Autorregressivo Integrado de Médias Móveis (ARIMA) e Autorregressivo Integrado de Médias Móveis Sazonais (SARIMA);
- d) Definir o modelo mais assertivo para cada período de previsão (6, 12 e 18 meses) e aplicá-los na série analisada;
- e) Identificar o modelo com menor erro quadrático médio e aplicar na série completa para detectar principais oscilações (positivas e negativas) históricas no preço da gasolina;
- f) Realizar uma análise causal das oscilações detectadas e determinar os principais fatores externos de impacto no preço da gasolina no Brasil.

1.3 JUSTIFICATIVA

Mesmo com a recuperação da safra de cana-de-açúcar ter aumentado a produção do Etanol, estima-se um crescimento de 0,3% na demanda da gasolina até o final de 2023, mantendo a representatividade do produto no setor energético (EPE, 2023). Segundo o IPCA (Índice Nacional de Preços ao Consumidor Amplo), a

gasolina é um dos fatores de maior peso para o cálculo da inflação no setor de transportes em setembro de 2023, reportado com uma variação de +1,4%, sendo acima do índice geral com resultado de +0,23% para a mesma avaliação (CARTA CAPITAL, 2023).

Ademais, na literatura dos últimos cinco anos, encontram-se, em grande maioria, análises que subsidiam a precificação de combustíveis alternativos, principalmente devido a introdução de carros *flex* no mercado brasileiro, a recuperação da safra de cana-de-açúcar e o incentivo fiscal para a produção de carros elétricos (ANDRADE, 2023; BIASE E SILVA, 2013). Frente a este cenário, faz-se necessário conduzir análises atualizadas sobre a gasolina, que ofereçam auxílio na tomada de decisão assertiva de empresas do setor de combustíveis, assim como do governo e dos consumidores.

Em relação ao método abordado, entende-se que análises de séries temporais para a previsão de preços são crescentes na literatura, como por exemplos os estudos de Santos e Chaucoski (2022) e Turqueti (2022), utilizando modelagens com a Autorregressiva Integrada de Médias Móveis (ARIMA) e suas variações para determinar o comportamento do preço de bens e *commodities*.

Dessa maneira, devido sua popularidade nos artigos recentes, selecionou-se o ARIMA, seus precedentes e suas variações para a condução deste trabalho. Como consequência, pode-se adicionar a literatura, se de fato, as evoluções das modelagens até o ARIMA (ARÊDES E PEREIRA, 2008; BANDURA ET AL., 2019; OLIVEIRA E CRISÓSTOMO, 2015; SATO, 2013; XAVIER, 2016) são promissoras ou descartáveis para a série analisada.

Além disto, este trabalho está sendo desenvolvido no curso de Gestão de Informação na Universidade Federal do Paraná, pois abrange diversos conceitos ministrados nas disciplinas ao longo da graduação. Por exemplo, as disciplinas de Mineração de Dados, de Métodos Quantitativos e de Inteligência Artificial Aplicada à Gestão da Informação fornecem a base de conhecimento para coleta e tratamento de dados, assim como também para a modelagem assertiva de diferentes métodos de análise. Em adicional, outras disciplinas como Análise de Dados e Tecnologia para Apoio à Tomada de Decisão, também fornecem subsídio na análise eficiente de resultados para facilitar a tomada de decisão em temas organizacionais, governamentais, entre outros relacionados com a sociedade.

Dessa maneira, o desenvolvimento deste trabalho permite aprimorar a capacidade de trabalhar com ferramentas analíticas e de programação, como Python e Excel, habilidades que são essenciais em muitas áreas profissionais. A integração desses conhecimentos técnicos com a teoria aprendida nas disciplinas do curso demonstra a capacidade de aplicar teorias acadêmicas em situações práticas, sendo um diferencial importante no mercado de trabalho.

2 REVISÃO DE LITERATURA

Esta seção apresenta a fundamentação teórica, que inclui a gasolina, séries temporais (ST) e os modelos utilizados para fazer a previsão do preço da gasolina.

Sobre o primeiro tópico, apresentam-se a definição e relevância do produto no Brasil atualmente, assim como a variação de preço e seus impactos sociais. Em seguida, introduz-se o conceito de séries temporais para análise e compreensão de dados. Por final, abordam-se os modelos utilizados para realizar a previsão e análise causal da variação do preço de combustíveis no Brasil, envolvendo abordagens correlacionadas, tais como a Autorregressiva (AR), a de Médias Móveis (MA), a Autorregressiva de Médias Móveis (ARMA), a Autorregressiva Integrada de Médias Móveis (ARIMA) e a Autorregressiva Integrada de Médias Móveis Sazonais (SARIMA).

2.1 GASOLINA: RELEVÂNCIA E PRECIFICAÇÃO NO BRASIL

Os combustíveis são essenciais para o desenvolvimento da sociedade humana desde o século XX, pois sua versatilidade na produção de energia possibilita o desenvolvimento de atividades industriais e a locomoção de pessoas e bens, por meio de automóveis, motocicletas, navios e aviões (PRAUCHNER ET AL., 2022). Como consequência, diferentes tipos de combustíveis foram desenvolvidos para sanar as necessidades da sociedade, sendo alguns provenientes de fontes renováveis, e outros de origem fóssil (petróleo), como a gasolina (BIASE E SILVA, 2013).

Segundo a CNN Brasil (2023), tem-se a previsão de que a demanda de gasolina irá subir em mais de 3% entre 2022 e 2023. Apesar do país ser independente no processo da extração do petróleo, a falta de conhecimento e

técnicas para seu refinamento e produção de gasolina, demanda que o Brasil importe o combustível, encarecendo o preço do produto (PUCRS, 2023). Como consequência, sendo a gasolina um dos principais fatores de impacto na inflação do país, o aumento no preço do produto restringe o poder de compra da população, pois outros bens e alimentos também sofrem elevação de preço (FONSECA, 2023).

Assim, como contramedida para evitar o aumento no preço da gasolina no Brasil, sem reduzir o lucro das petroleiras locais, o Ministro da Fazenda e o Ministro de Minas e Energia, decretaram em 2023 o aumento nas tarifas de exportação de petróleo em 9,2% para compensar a perda financeira na venda do combustível, tendo impostos parcialmente aplicados sobre o preço de revenda do produto no país (TOMAZELLI, GARCIA E BRANT, 2023).

Entretanto, entende-se na literatura que, além das políticas governamentais e da oscilação na demanda da gasolina, diversos outros complexos e interligados fatores afetam o preço do produto, sendo os principais, a política de preço das petrolíferas, as políticas governamentais e as mudanças globais no comportamento do mercado (FONSECA, 2023).

Até 2002, quando o setor de combustíveis entrou no livre mercado e as petroleiras desenvolveram a autonomia na precificação do produto, os preços da gasolina eram definidos pelo governo, por meio de decretos, com diferentes regulamentações entre regiões (MARJOTTA-MAISTRO E BARROS, 2003). Nos últimos anos, a petrolífera local (Petrobras) adotava a política de Preços de Paridade de Importação (PPI), onde o dólar era a base para o cálculo, assim como a demanda de empresas estrangeiras que exportavam gasolina para o Brasil, causando volatilidade no preço do insumo (AGÊNCIA SENADO, 2023; IBPT, 2023). Em 2023, o presidente da Petrobras afirmou que a nova política de precificação da gasolina considera primordialmente a moeda e a demanda local do mercado, causando maior estabilidade e tornando o preço do produto mais justo para o cliente final (AGÊNCIA SENADO, 2023; IBPT, 2023).

Ademais, a mudança na oferta e demanda do mercado de gasolina foi impactada pelo lançamento de veículos *flex* (automóveis movidos à álcool e gasolina), os quais revolucionaram o comportamento dos consumidores, possibilitando maior flexibilidade na escolha de produtos substitutos (como o etanol), não apenas no ato da compra do veículo (BIASE E SILVA, 2013). Além disto, o Vice-Presidente atual do governo brasileiro decretou incentivo fiscal para montadoras,

fomentando a produção de veículos elétricos no país com preço reduzido de até 11%, corroborando a consolidação do produto no mercado local (ANDRADE, 2023). Como consequência, o aumento no preço da gasolina incentiva, a curto prazo, a substituição do produto pelo etanol; e a longo prazo, por biocombustíveis (MELO, 2012).

2.2 ANÁLISE DE SÉRIES TEMPORAIS (ST)

As técnicas de previsão auxiliam na redução de riscos, tais como a oscilação de preços, para setores que necessitam de planejamento, avaliação e políticas para redução de incertezas (BRESSAN, 2004). Segundo Makridakis et al. (1982) e Campos (2008), há diferentes técnicas de previsão, podendo ser subjetivas por meio de conversas com especialistas, econométricos (teoria econômica e técnicas estatísticas) ou modelos extrapolativos, como séries temporais.


Uma série temporal univariada conceitua-se como um conjunto de observações escalares ordenadas em um intervalo de tempo na forma de $X_t = \{x_0, x_1, x_2, \dots, x_T\}$, com o objetivo de determinar a dependência entre cada observação e seus valores históricos (SILVA, 2021; SILVA, GUIMARÃES E TAVARES, 2008). Este tipo de análise é comumente utilizado devido sua rapidez e facilidade de aplicação, possibilitando a investigação causal das oscilações da série; podendo também ser combinada com outras séries temporais para determinar o comportamento entre variáveis (BRESSAN, 2004; ANGELO ET AL., 2011).

As séries temporais podem ser caracterizadas de acordo com a sua linearidade, estocasticidade e estacionariedade (SILVA, 2021). Séries lineares assumem valores de combinações lineares entre a variável e suas observações e ruídos históricos (média ou variância), senão conceitua-se como uma série não-linear (CRUZ, 2021; SILVA, 2021). Uma série temporal é caracterizada como determinística (ou derivada) quando compreende observações que dependem rigorosamente das históricas; enquanto as estocásticas (aleatórias) são compostas por uma sequência de observações aleatórias que seguem funções de densidade de probabilidade e podem ser voláteis ao longo do tempo (FERREIRA, 2014; SILVA, 2021). Por fim, séries estacionárias possuem equilíbrio estatístico ao longo do tempo (média e variância constante), não havendo tendência de aumento ou decréscimo; caso

contrário, são caracterizadas como séries não-estacionárias (SANTOS ET AL., 2016).

A abordagem mais tradicional para caracterizar séries temporais consiste em técnicas de alisamento ou decomposição, podendo ser uma decomposição aditiva (somatório dos componentes) ou multiplicativa (produto dos componentes) (Figura 1) (CAMPOS, 2008). Como resultado, identificam-se três principais componentes das séries analisadas: tendência (comportamento positivo ou negativo de crescimento das observações a longo prazo), sazonalidade (função seno com frequência angular de π representando os padrões que a série obedece) e resíduo (flutuações de curto período na série, geralmente com média igual a zero e desvio padrão de 0,5) (ANGELO ET AL., 2011; BOUZADA, 2012; CRUZ, 2021; SILVA, 2018). Entretanto, para definir se uma série temporal é estacionária, a visualização gráfica da decomposição é insuficiente, sendo comumente utilizada em conjunto com testes estatísticos como Dickley-Fuller Aumentado (ADF), Phillips-Perron ou testes de KPSS (XAVIER, 2016).

FIGURA 1 - EXEMPLO DE DECOMPOSIÇÃO ADITIVA DE SÉRIE TEMPORAL



FONTE: Adaptado de Silva, LÚCIO E MARROM (2016).

Com isto, a análise de séries temporais será utilizada para cumprir o segundo objetivo específico deste trabalho, tornando possível definir os modelos coerentes para a realização de previsões de curto-prazo, com padrões sistemáticos de comportamento (BOUZADA, 2012; BRESSAN, 2004; CAMPOS, 2008).

2.3 MÉTODO DE PREVISÃO AUTORREGRESSIVOS E DE MÉDIAS MÓVEIS COM SÉRIES TEMPORAIS

Os modelos de previsão de dados em séries temporais foram criados com o objetivo de descrever as alterações nas observações e prever o comportamento esperado de uma variável com base nos seus resultados históricos, por meio de uma abordagem matemática (BANDURA ET AL., 2019; OLIVEIRA E CRISÓSTOMO, 2015; SATO, 2013; XAVIER, 2016). Os métodos baseados em médias móveis e autorregressão são comumente aplicados desde o início do século XXI, utilizando as observações históricas para determinar o futuro e assumindo que a série siga uma distribuição normal, seja linear e estacionária (em sua maioria) (CRUZ, 2021; XAVIER, 2016).

A seguir, são apresentados os principais modelos de previsão de séries temporais com a abordagem autorregressiva de médias móveis, os quais serão utilizados para cumprir o terceiro objetivo específico deste trabalho.

2.3.1 Modelo Autorregressivo (AR)

O modelo AR é conceituado como autorregressivo de ordem $AR(p)$, onde p significa o número de termos autorregressivos; ou seja, sua aplicação apenas é viável quando a série é estacionária e existe correlação entre as observações da série temporal (OLIVEIRA E CRISÓSTOMO, 2015; XAVIER, 2016).

Para que seja possível determinar o valor de p , utilizam-se as funções de autocorrelação (FAC) e principalmente, de autocorrelação parcial (FACP), visando minimizar o erro do modelo na obtenção das previsões – critérios de Akaike (AIC) e Schwarz (SC) (ARÊDES E PEREIRA, 2008).

Como exemplo, tem-se o estudo de Kassouf (1988), avaliando o preço do boi no Brasil, por meio dos modelos AR, ARIMA e SARIMA, sendo os dois primeiros considerados como satisfatórios pela autora, para a série temporal analisada. Outro exemplo é o estudo de Nogueira (2023), analisando a precificação da cana-de-açúcar no Brasil por meio do modelo AR de ordem 1 pela facilidade de aplicação, sem definição de sua assertividade por parte dos autores, pois não foi comparado com outros modelos de predição.

2.3.2 Modelo de Médias Móveis (MA)

O modelo MA possui a ordem $MA(q)$, onde q simboliza a quantidade de termos de médias móveis (XAVIER, 2016). O objetivo deste modelo é investigar a autocorrelação dos resíduos da previsão em séries temporais estacionárias, presentes em cada q termo das séries (OLIVEIRA E CRISÓSTOMO, 2015).

Para que seja possível determinar o valor de q , utiliza-se a função de autocorrelação (FAC), visando minimizar o erro do modelo na obtenção das previsões da série analisada – critérios de Akaike (AIC) e Schwarz (SC) (ARÊDES E PEREIRA, 2008; XAVIER, 2016).

Como exemplo, o estudo de Akrami et al. (2014) analisa a precipitação da chuva para a gestão da água na Malásia, comparando modelos, incluso o MA. Outro exemplo é o trabalho de Ivanovski et al. (2018) realizando a previsão da quantidade de turistas na Macedônia, por meio de modelos de médias móveis com séries temporais.

2.3.3 Modelo Autorregressivo de Médias Móveis (ARMA)

O modelo ARMA é a junção dos modelos anteriores AR e MA, sendo conceituado como autorregressivo de ordem $ARMA(p,q)$, onde p significa a quantidade de termos autorregressivos e q o número de termos de médias móveis; ou seja, é necessário que a série temporal seja estacionária com correlação entre as observações e autocorrelação dos resíduos das previsões (OLIVEIRA E CRISÓSTOMO, 2015; XAVIER, 2016).

Da mesma forma que nos dois modelos anteriores, os valores de p e q devem visar reduzir o erro na previsão da série analisada – critérios de Akaike (AIC) e Schwarz (SC) –, sendo obtidos por meio das funções de autocorrelação (FAC) e autocorrelação parcial (FACP) (ARÊDES E PEREIRA, 2008).

Como por exemplo, o estudo de Lima et al. (2007), utilizando o modelo ARMA e ARIMA em comparação com modelos que possuem diferenciação fracionada, sendo estes com resultados mais assertivos na maioria dos testes da série analisada sobre preços de *commodities* agrícolas. Além disto, o estudo de Cas

(2018) utiliza o modelo ARMA para previsão do preço do milho no Brasil, obtendo resultados satisfatórios para a série temporal analisada de ordem ARMA(1,2).

2.3.4 Modelo Autorregressivo Integrado de Médias Móveis (ARIMA)

Desenvolvido por George Box e Gwilym Jenkins na década de 70, o modelo ARIMA é estatístico linear e tem o objetivo de fazer previsões de curto-prazo para séries temporais, buscando reduzir a zero a diferença entre os valores do modelo e os observados na série (SATO, 2013; XAVIER, 2016).

O modelo possui ordem de ARIMA(p,d,q), onde p refere-se ao número de termos autorregressivos, d é o número de diferenciações para que a série se torne estacionária, e q condiz aos termos de médias móveis do modelo; sendo todos inteiros e maiores ou iguais a zero (BANDURA ET AL., 2019; XAVIER, 2016).

O diferencial deste modelo frente aos anteriores é a sua maior versatilidade na aplicação, uma vez que se faz possível utilizar para séries estacionárias e não-estacionárias, pois o ARIMA integra a diferenciação para manter a média e a variação constantes na série (ARÊDES E PEREIRA, 2008; BANDURA ET AL., 2019; 2020; OLIVEIRA E CRISÓSTOMO, 2015; SATO, 2013). Assim, faz-se possível empregar o ARIMA para descrever, interpretar e realizar análises causais sobre comportamentos e tendências presentes nas observações (BANDURA ET AL., 2019).

Como exemplo, tem-se o estudo de Oliveira e Crisóstomo (2015), analisando a assertividade do modelo ARIMA para a previsão de volume de exportação de frutos brasileiros, tendo um resultado positivo para 60% das frutas analisadas.

2.3.5 Modelo Autorregressivo Integrado de Médias Móveis Sazonais (SARIMA)

O modelo SARIMA é uma variação do anterior ARIMA, criado com base em Box-Jenkins, seguindo o mesmo processo e critérios, porém incluem a correlação serial da sazonalidade das observações (BANDURA ET AL., 2019; CHECHI E BAYER, 2012; XAVIER, 2016). Assim, o modelo é de ordem SARIMA(p,d,q)(P,D,Q), onde P representa os termos sazonais autorregressivos, o Q é o termo de média móvel sazonal e o D é a ordem de diferenciação sazonal para a série temporal analisada (ARÊDES E PEREIRA, 2008; CHECHI E BAYER, 2012).

Como exemplo, tem-se o estudo de Silva, Guimarães e Tavares (2008), envolvendo a previsão de temperaturas climáticas em Uberlândia (Minas Gerais) por meio do método SARIMA. Outro exemplo é o estudo de Santos et al. (2023), onde comparou-se os modelos SARIMA e *Long Short-Term Memory*, para a previsão do preço do milho no Brasil, sendo que o segundo modelo apresentou menor erro médio absoluto para um horizonte de seis meses da série analisada.


3 MATERIAL E MÉTODOS

A metodologia tem a finalidade de definir os processos da construção de conhecimento científico, estabelecendo técnicas para a padronização de coleta e análise de informações (SILVA E SILVA, 2015). Dessa maneira, segundo Vergara (2005), faz-se vital a seleção adequada do método de conduta do estudo para que seja possível responder ao problema central de pesquisa. Assim, apresentam-se neste capítulo, os desenhos de pesquisa e os processos de coleta, tratamento, modelagem e análise dos dados.

3.1 DESENHO GERAL DE PESQUISA

Após a identificação da lacuna na literatura e definição do problema de pesquisa, este estudo foi dividido em 4 (quatro) etapas, com base na metodologia de Box e Jenkins (1976): (a) Coleta de dados sobre o preço da gasolina no Brasil; (b) Tratamento de dados para a construção da série temporal; (c) Modelagem dos métodos de previsão de preço; e (d) Análise causal das principais oscilações no preço do combustível. A seguir, apresentam-se o desenho geral de pesquisa, seguido pelos desenhos e detalhamento de cada etapa (Figura 2).

FIGURA 2 - DESENHO GERAL DE PESQUISA




FONTE: O autor (2024) com base em Box e Jenkins (1976).

3.1.1 Coleta de Dados

A primeira etapa envolve a coleta de dados dos preços de gasolina no Brasil ao longo da última década, abrangendo de janeiro de 2013 até novembro de 2023. A seguir, dispõe-se o fluxo detalhado desta etapa na Figura 3.

FIGURA 3 - DESENHO DE PESQUISA: ETAPA (A) COLETA DE DADOS



FONTE: O autor (2024).


Com o objetivo de coletar dados fidedignos, utilizou-se a base oficial do governo denominada Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), a qual é um centro de referência sobre informações da indústria do petróleo e gás natural, com o objetivo de divulgar estatísticas sobre o produto no Brasil, manter o banco de dados atualizado, conduzir e divulgar pesquisas relacionadas com *commodities* energéticas, entre outras funções (ANP, 2023).

Esta base é aberta, sem restrições de acesso e contém dois documentos para cada ano da precificação, de 2001 até 2023. Para cada observação diária nos documentos, é possível encontrar o estado, o município e a quantidade de postos pesquisados para cada tipo de combustível (etanol, gasolina, GLP, GNV e óleo diesel), assim como também a unidade de medida, o preço médio, o desvio padrão, o preço mínimo, o preço máximo e o coeficiente de variação do preço de revenda dos produtos.

3.1.2 Tratamento de Dados

A segunda etapa envolve o tratamento de dados, com o objetivo principal de filtrar as informações desejadas para a análise e prepará-las para a construção da série temporal. A seguir, dispõe-se o fluxo detalhado desta etapa na Figura 4.

FIGURA 4 - DESENHO DE PESQUISA: ETAPA (B) TRATAMENTO DE DADOS



FONTE: O autor (2024).

O primeiro passo dessa etapa envolve a junção de todas as bases anuais de dados coletadas na base da ANP, para que seja possível a posterior criação da série de dados com todas as informações necessárias para responder ao problema de pesquisa.

O segundo passo envolve filtrar a base para que seja possível realizar uma análise assertiva, visando a previsão do preço apenas do combustível gasolina comum. Depois, o terceiro passo envolve a seleção dos dados a serem trabalhados na análise, englobando as datas de observação, as quais compõem o eixo X da série temporal, e o preço médio de revenda, apresentado no eixo Y da série temporal.


Em seguida, uma vez que os dados estão dispostos por estado e o objetivo de pesquisa visa uma análise nacional, o quarto passo engloba realizar a média dos estados para cada dia, resultando em um valor de preço de revenda único nacional diário. Entretanto, como o preço da gasolina não é volátil em medida de dias e a base de dados não possui assertivamente 365 observações anuais, criam-se observações quinzenais nacionais, resultantes da média dos 15 dias anteriores para a primeira e segunda quinzena de cada mês. Assim, será possível obter 2 observações por mês, em um espaço de tempo de 10 anos, resultando em um total de 240 observações para compor a série temporal.

Por fim, caso ainda haja alguma observação faltante, o quinto passo tem o objetivo de suprir as lacunas com o valor da média dos últimos 3 pontos de observações existentes, calculados no passo anterior. Dessa forma, os dados estarão contínuos e coerentes para a modelagem e desenvolvimento da previsão de preços da gasolina.

3.1.3 Modelos de Predição

A terceira etapa envolve a modelagem dos dados, por meio da ferramenta *Notebook Jupyter* (com programação em linguagem *Python*), envolvendo 4 (quatro) processos (Figura 5): (a) Definição das bases e período de predição; (b) Modelagem dos modelos de predição; (c) Definição do modelo acurado para cada período de predição; e, (d) Previsão do preço da gasolina no Brasil.

FIGURA 5 - DESENHO DE PESQUISA: ETAPA (C) MODELOS DE PREDIÇÃO



FONTE: O autor (2024).

Para o primeiro processo, foi estabelecido 3 (três) períodos de previsão: 6 meses, 12 meses e 18 meses. Como a base oferece valores médios quinzenais de preço do combustível, tais períodos representam, consecutivamente, 12, 24 e 36 observações, e foram delimitados como a base teste de validação para cada modelo criado.

Assim, para validar cada um destes cenários, tem-se 5 (cinco) diferentes bases históricas (base treino), contemplando 100%, 125%, 150%, 175% e 200% do período de teste para cada cenário (Tabela 1).

TABELA 1 - PERÍODO HISTÓRICO BASE PARA ANÁLISE DOS MODELOS PREDITIVOS

Base de dado histórica para o modelo	Meses de previsão		
	6 meses (12 observações)	12 meses (24 observações)	18 meses (32 observações)
100% do período de previsão	6 meses (12 observações)	12 meses (24 observações)	18 meses (32 observações)
125% do período de previsão	8 meses (16 observações)	15 meses (30 observações)	23 meses (46 observações)
150% do período de previsão	9 meses (18 observações)	18 meses (32 observações)	27 meses (54 observações)
175% do período de previsão	11 meses (22 observações)	21 meses (42 observações)	32 meses (64 observações)
200% do período de previsão	12 meses (24 observações)	24 meses (48 observações)	36 meses (72 observações)

FONTE: O autor (2024).

Sendo assim, a Tabela 2 demonstra o período utilizado para cada base teste e treino, dos 15 cenários de previsão construídos (3 períodos de previsão contemplando 5 bases históricas cada).

TABELA 2 - PERÍODO DA SÉRIE TEMPORAL UTILIZADO PARA TREINO E TESTE PARA CADA ABORDAGEM DE PREDIÇÃO REALIZADA

Base de dados histórica para o modelo		Meses de previsão					
		6 meses		12 meses		18 meses	
		Treino	Teste	Treino	Teste	Treino	Teste
100% do período de previsão	Início	01/01/2023	01/07/2023	01/01/2022	01/01/2023	01/01/2021	01/07/2022
	Fim	30/06/2023	31/12/2023	31/12/2022	31/12/2023	30/06/2022	31/12/2023
125% do período de previsão	Início	01/11/2022	01/07/2023	01/10/2021	01/01/2023	01/08/2020	01/07/2022
	Fim	30/06/2023	31/12/2023	31/12/2022	31/12/2023	30/06/2022	31/12/2023
150% do período de previsão	Início	01/10/2022	01/07/2023	01/07/2021	01/01/2023	01/04/2020	01/07/2022
	Fim	30/06/2023	31/12/2023	31/12/2022	31/12/2023	30/06/2022	31/12/2023
175% do período de previsão	Início	01/08/2022	01/07/2023	01/04/2021	01/01/2023	01/11/2019	01/07/2022
	Fim	30/06/2023	31/12/2023	31/12/2022	31/12/2023	30/06/2022	31/12/2023
200% do período de previsão	Início	01/07/2022	01/07/2023	01/01/2021	01/01/2023	01/07/2019	01/07/2022
	Fim	30/06/2023	31/12/2023	31/12/2022	31/12/2023	30/06/2022	31/12/2023

FONTE: O autor (2024).

O segundo processo visa aplicar tais bases em 5 (cinco) diferentes abordagens de modelos preditivo (a) AR – Autorregressivo; (b) MA – Médias Móveis; (c) ARMA – Autorregressivo de Médias Móveis; (d) ARIMA – Autorregressivo Integrado de Médias Móveis; e, (e) SARIMA – Autorregressivo Integrado de Médias Móveis Sazonais.

Para cada modelo, estressa-se o processo para obter as ordens p , q e d (sendo de zero até 10 – exceto a diferenciação que varia de zero até dois), selecionando a combinação que possui o menor valor de Aikake (AIC). Assim, como resultado, tem-se uma tabela com a ordem e o AIC do modelo, para cada cenário anteriormente explicado.


O terceiro processo engloba treinar os modelos desenvolvidos anteriormente para obter o período de previsão similar ao período da base teste. Desta forma, faz-se possível calcular o Erro Quadrático Médio (EQM) para cada base histórica e período de predição.

Por fim, seleciona-se o melhor modelo, ou seja, com o menor EQM (CHECHI E BAYER, 2012) para cada cenário e aplicá-lo para a previsão dos próximo 6, 12 e 18 meses do valor do preço da gasolina no Brasil, contando a partir do último dado disponível na base (31 de dezembro de 2023), fornecendo valores quinzenais de previsão.

3.1.4 Análise Causal de Oscilações

As análises qualitativas de dados têm a finalidade de expandir o conhecimento teórico e prático sobre o tema abordado (BRUGGEMANN; PARPINELLI, 2008; SERRA; FERREIRA, 2016). Sendo assim, conduz-se uma análise da série temporal com o objetivo de compreender fatores externos que corroboram nas oscilações, positivas e negativas, do preço da gasolina no Brasil. A seguir, apresenta-se o desenho de pesquisa detalhado da etapa da análise causal (Figura 6).

FIGURA 6 - DESENHO DE PESQUISA:ETAPA (D) ANÁLISE CAUSAL



FONTE: O autor (2024).

O primeiro passo envolve utilizar o modelo selecionado na etapa anterior (c) para realizar a previsão do preço da gasolina para cada observação da série temporal. Em seguida, calcula-se o erro quadrático médio (EQM) e a variação entre a média do previsto e do real de cada observação da série temporal analisada.

O EQM em uma série temporal tem a finalidade de indicar a acurácia do modelo e determinar períodos atípicos na série de dados (CHECHI E BAYER, 2012). Assim, em conjunto com a variação, faz-se possível detectar períodos nos quais o valor real da gasolina oscila em maior grandeza, positiva ou negativamente, comparado com a tendência prevista baseada no histórico dos preços. Dessa maneira, o quinto passo envolve a seleção dos períodos de observação que obtiveram os maiores e menores valores de EQM e variação, indicando os pontos de oscilação no preço da gasolina que foram impactados por fatores externos aos próprios dados analisados, uma vez que a predição foi realizada com um modelo assertivo para a série.

Em seguida, para cada período atípico detectado no passo anterior, procuram-se notícias de fontes confiáveis para compreender quais tipos de fatores externos afetam a variação do preço da gasolina, como por exemplo, inflação, epidemias, guerras, mudanças de mercado, mudanças governamentais, entre outros. Por fim, conduz-se uma análise com tais resultados para determinar quais são os principais fatores que, além da previsão, devem ser ponderados na definição da precificação da gasolina no país.

4 APRESENTAÇÃO DOS RESULTADOS

Buscando responder os objetivos específicos desta pesquisa, primeiramente, tem-se o desenvolvimento da seção 2 (dois) - Referencial Teórico -, abordando o impacto da precificação da gasolina no Brasil, o conceito de séries temporais e de previsão de preço, por meio da condução de uma revisão da literatura sobre os temas.

Além disto, destacam-se outros 3 (três) resultados: (a) Características da série temporal do preço do combustível no país; (b) Definição do modelo de previsão ajustado para a série e suas previsões futuras de preço; e, (c) Principais elementos externos impactantes na oscilação da série.

A seguir, tem-se tais resultados explicados em detalhes.

4.1 CARACTERÍSTICAS DA SÉRIE TEMPORAL DE PREÇO DA GASOLINA NO BRASIL

Após a coleta e tratamento de dados descritos na seção 3.1, fez-se possível a criação da série temporal do preço da gasolina no Brasil (Figura 7), abrangendo janeiro de 2013 até dezembro de 2023, contemplando plotagens do preço médio quinzenal ao longo do período.

FIGURA 7 - SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL



FONTE: O autor (2024).

Para o desenvolvimento do gráfico, utilizou-se a ferramenta *Jupyter Notebook* com a linguagem de programação *Python*, importando as bibliotecas *matplotlib*.

Em seguida, com o objetivo de compreender as principais características da série temporal, importou-se a biblioteca *statsmodels* para realizar a decomposição aditiva dos dados, por possuir variância significativamente baixa ao longo da série (Figura 8).

FIGURA 8 - ALGORITMO EM PYTHON PARA A DECOMPOSIÇÃO ADITIVA DA SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL

```
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
from statsmodels.tsa.seasonal import seasonal_decompose

# Carregar os dados do arquivo Excel com formatação de data especificada
data_frame = pd.read_excel("C:/Users/ricar/OneDrive/Área de Trabalho/TCC/base_preco_gasolina_2013_2023.xlsx",
                           index_col=0, parse_dates=True) # Usando a coluna B como índice

# Criar uma série temporal com a coluna correta como valores
ts = pd.Series(data_frame[data_frame.columns[0]])

# Decomposição sazonal
decomposicao = seasonal_decompose(ts, model='additive', period=24)

# Plotar os componentes
fig, (ax1, ax2, ax3, ax4) = plt.subplots(4, 1, figsize=(8, 10))
ts.plot(ax=ax1, title='Valores Observados')
decomposicao.trend.plot(ax=ax2, title='Tendência da Série Temporal')
decomposicao.seasonal.plot(ax=ax3, title='Sazonalidade')
decomposicao.resid.plot(ax=ax4, title='Resíduos')

# Ajustar Layout
plt.tight_layout()


# Salvar a imagem
plt.savefig("decompose.png")

plt.show()
```

FONTE: O autor (2024) com base em ASSAOKA (2024).

Como resultado, obteve-se a tendência, sazonalidade e resíduo da série analisada (Figura 9).

FIGURA 9 - DECOMPOSIÇÃO DA SÉRIE TEMPORAL DO PREÇO DA GASOLINA NO BRASIL



FONTE: O autor (2024).

Em suma, com base no primeiro gráfico, compreende-se que a série possui uma tendência crescente não linear ao longo da década analisada, indicando que há mais de um tipo de comportamento ao longo do período (CRUZ, 2021; SILVA, 2021). Como por exemplo, é possível detectar uma tendência crescente na precificação da gasolina no Brasil entre 2013 e 2022, e também a partir de 2023; sendo o ano de 2022 representado por uma inclinação negativa.

Além disto, a série apresenta uma certa sazonalidade demonstrada no segundo gráfico, contendo padrões regulares e previsíveis em intervalos menores de 1 ano (ANGELO ET AL., 2011; BOUZADA, 2012; CRUZ, 2021; SILVA, 2018). Por fim, o terceiro gráfico indica que há uma parcela de dados, denominada resíduos, que possui comportamento estocástico (aleatório) e não pode ser explicada pelas duas características anteriores (FERREIRA, 2014; SILVA, 2021).

4.2 MODELOS E RESULTADOS DE PREVISÕES

Nesta seção serão apresentados os modelos de previsão desenvolvidos neste trabalho e o valor de previsão do preço da gasolina no Brasil para os próximos 6, 12 e 18 meses, a contar do fim da base de dados utilizada (dezembro de 2023).

4.2.1 Modelos

Após a compreensão da série temporal analisada, buscou-se encontrar o modelo mais assertivo para realizar a previsão do preço da gasolina no Brasil para os próximos 6 (seis), 12 (doze) e 18 (dezoito) meses.

Para isto, foram utilizadas 5 (cinco) diferentes abordagens de modelos preditivo (a) AR – Autorregressivo; (b) MA – Médias Móveis; (c) ARMA – Autorregressivo de Médias Móveis; (d) ARIMA – Autorregressivo Integrado de Médias Móveis; e, (e) SARIMA – Autorregressivo Integrado de Médias Móveis Sazonais; considerando que as bases de teste são semelhantes a cada período de previsão analisado, e as bases de treino representam um período de 100, 125, 150, 175 e 200% relativos às bases treino.

A Tabela 3 apresenta os resultados referentes ao método AR. Na primeira coluna estão dispostos os tamanhos das bases de treino consideradas para gerar os modelos, visando a previsão dos períodos indicados nas colunas. Para cada um

desses, tem-se o menor valor de AIC obtido, juntamente com o valor do parâmetro (p) (XAVIER, 2016). Os asteriscos representam a quantidade de vezes que a série foi diferenciada para tornar-se estacionária e viabilizar a aplicação do modelo (OLIVEIRA E CRISÓSTOMO, 2015).

TABELA 3 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO DE AUTORREGRESSÃO

Modelo	AR					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	(p)	AIC	(p)	AIC	(p)
100% da base teste	-8,41	(8)	5,80	(1)	-51,90	*(1)
125% da base teste	-13,66	*(9)	-5,65	*(1)	-69,63	*(2)
150% da base teste	-8,35	** (1)	-14,22	*(1)	-84,63	*(2)
175% da base teste	-13,26	** (1)	-22,85	*(1)	-107,89	*(1)
200% da base teste	-12,21	(3)	-27,40	*(1)	-130,72	*(1)

FONTE: O autor (2024).

A Tabela 4 apresenta os resultados de AIC e parâmetro (q) (XAVIER, 2016) referentes ao método de MA. Na primeira coluna estão descritas as bases de treino utilizadas na previsão dos períodos indicados nas colunas. Os asteriscos representam a quantidade de vezes que a série foi diferenciada para tornar-se estacionária e viabilizar a aplicação do modelo (OLIVEIRA E CRISÓSTOMO, 2015).

TABELA 4 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO DE MÉDIAS MÓVEIS

Modelo	MA					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	(q)	AIC	(q)	AIC	(q)
100% da base teste	-8,98	(1)	22,26	*(1)	-41,36	*(1)
125% da base teste	-1,90	*(1)	-2,16	*(1)	-55,74	*(1)
150% da base teste	15,26	*(1)	-8,98	*(1)	-72,79	*(1)
175% da base teste	-18,40	(1)	-16,01	*(1)	-144,46	*(1)
200% da base teste	-10,93	(1)	20,91	*(1)	-115,47	*(1)

FONTE: O autor (2024).

A Tabela 5 apresenta os resultados referentes ao método de ARMA. Na primeira coluna estão dispostos os tamanhos das bases de treino consideradas para gerar a previsão dos períodos indicados nas colunas. Para cada um desses, tem-se o menor valor de AIC e parâmetros (p,q) (XAVIER, 2016) obtidos ao estressar o modelo. Os asteriscos representam a quantidade de vezes que a série foi diferenciada para tornar-se estacionária e possibilitar a aplicação do modelo (OLIVEIRA E CRISÓSTOMO, 2015).

TABELA 5 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTORREGRESSIVO DE MÉDIAS MÓVEIS

Modelo	ARMA					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	(p,q)	AIC	(p,q)	AIC	(p,q)
100% da base teste	-8,98	(1,0)	4,87	** (0,0)	-51,90	* (1,0)
125% da base teste	-14,52	* (0,0)	-5,65	* (1,0)	-69,63	* (2,0)
150% da base teste	-8,35	** (1,0)	-14,22	* (1,0)	-84,63	* (2,0)
175% da base teste	-13,26	** (1,0)	-22,85	* (1,0)	-107,89	* (1,0)
200% da base teste	-15,97	(1,2)	-20,35	** (2,0)	-130,72	* (1,0)

FONTE: O autor (2024).

A Tabela 6 apresenta os resultados de menor AIC e seus respectivos parâmetros (p,q,d) (BANDURA ET AL., 2019) referentes ao método ARIMA. Na primeira coluna estão descritas as bases de treino para gerar a previsão dos períodos indicados nas colunas. Uma vez que o ARIMA possui a diferenciação integrada, não houve necessidade de diferenciar a base treino em nenhuma instância (ARÊDES E PEREIRA, 2008; SATO, 2013).

TABELA 6 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTORREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS

(continua)

Modelo	ARIMA					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	(p,q,d)	AIC	(p,q,d)	AIC	(p,q,d)
100% da base teste	-8,98	(0,1,0)	-1,24	(1,1,0)	-53,45	(0,1,1)
125% da base teste	-15,98	(0,1,0)	-7,46	(1,1,0)	-71,39	(0,1,1)

TABELA 6 – RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTOREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS

(conclusão)

Modelo	ARIMA					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	(p,q,d)	AIC	(p,q,d)	AIC	(p,q,d)
150% da base teste	-19,30	(0,1,0)	-1,10	(1,1,0)	-86,19	(0,1,1)
175% da base teste	-18,40	(0,1,0)	-24,81	(1,1,0)	-108,14	(0,1,2)
200% da base teste	-15,34	(2,1,0)	-29,35	(1,1,0)	-130,72	(0,1,1)

FONTE: O autor (2024).

Por fim, a Tabela 7 apresenta os resultados referentes ao método de SARIMA. Na primeira coluna estão dispostos os tamanhos das bases de treino consideradas para gerar os modelos, visando a previsão dos períodos indicados nas colunas. Para cada um desses, apresenta-se o menor valor de AIC obtido ao estressar o modelo, juntamente com valor dos parâmetros (p,q,d) e (P,Q,D) (ARÊDES E PEREIRA, 2008; CHECHI E BAYER, 2012). Uma vez que o modelo possui a diferenciação integrada, não houve necessidade de diferenciar a base treino em nenhuma instância (ARÊDES E PEREIRA, 2008; SATO, 2013).

TABELA 7 - RESULTADO DE ACORDO COM O PERÍODO DE PREVISÃO – MÉTODO AUTOREGRESSIVO INTEGRADO DE MÉDIAS MÓVEIS SAZONAIS

Modelo	SARIMA					
Previsão	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
Base treino	AIC	$(p,q,d)(P,Q,D)$	AIC	$(p,q,d)(P,Q,D)$	AIC	$(p,q,d)(P,Q,D)$
100% da base teste	-8,98	(0,1,0)(0,0,0)	-1,95	(1,1,0)(1,0,0)	-53,45	(0,1,1)(0,0,0)
125% da base teste	-15,98	(0,1,0)(0,0,0)	-7,46	(1,1,0)(0,0,0)	-71,39	(0,1,1)(0,0,0)
150% da base teste	-19,30	(0,1,0)(0,0,0)	-16,10	(1,1,0)(0,0,0)	-86,19	(0,1,1)(0,0,0)
175% da base teste	-18,40	(0,1,0)(0,0,0)	-24,81	(1,1,0)(0,0,0)	-108,14	(0,1,2)(0,0,0)
200% da base teste	-15,34	(2,1,0)(0,0,0)	-29,35	(1,1,0)(0,0,0)	-130,72	(1,1,0)(0,0,0)

FONTE: O autor (2024).

Após a obtenção dos parâmetros com menor erro AIC para cada cenário analisado, fez-se a previsão para os últimos períodos da base, contemplando 6, 12 e 18 meses. Isto possibilitou a comparação entre os valores obtidos pelos modelos e

os valores reais do preço do combustível no Brasil, calculando-se o EQM (Erro Quadrático Médio) (CHECHI E BAYER, 2012).

A Tabela 8 apresenta os modelos e bases de treinos avaliadas e suas respectivas ordens e EQMs. Os asteriscos representam a quantidade de vezes que a série foi diferenciada para tornar-se estacionária. Em azul, tem-se os modelos melhor ajustados para cada período de base teste (menor EQM) (CHECHI E BAYER, 2012).

TABELA 8 - RESULTADO DOS ERROS QUADRÁTICOS MÉDIOS DE CADA MODELO POR PERÍODO TESTE E TREINO AVALIADO

Modelo	Base treino	Base teste 6 meses		Base teste 12 meses		Base teste 18 meses	
		Ordem	EQM	Ordem	EQM	Ordem	EQM
AR	100%	(8)	0,28163	(1)	0,04777	*(1)	0,03526
AR	125%	*(9)	0,04278	*(1)	0,02284	*(2)	0,03534
AR	150%	*(1)	0,03680	*(1)	0,02170	*(2)	0,03306
AR	175%	*(1)	0,03697	*(1)	0,02077	*(1)	0,02913
AR	200%	(3)	0,06253	*(1)	0,01960	*(1)	0,02873
MA	100%	(1)	0,11747	*(1)	0,04939	*(1)	0,02980
MA	125%	*(1)	0,01378	*(1)	0,02248	*(1)	0,02980
MA	150%	*(1)	0,04055	*(1)	0,02248	*(1)	0,02980
MA	175%	(1)	0,11747	*(1)	0,02248	*(1)	0,02980
MA	200%	(1)	0,11747	*(1)	0,04939	*(1)	0,02980
ARMA	100%	(0,1)	0,11747	*(0,0)	0,04755	*(1,0)	0,03526
ARMA	125%	*(0,0)	0,01439	*(1,0)	0,02284	*(2,0)	0,03534
ARMA	150%	*(1,0)	0,03680	*(1,0)	0,02170	*(2,0)	0,03306
ARMA	175%	*(1,0)	0,03697	*(1,0)	0,02077	*(1,0)	0,02913
ARMA	200%	(1,2)	0,03864	*(2,0)	0,04737	*(1,0)	0,02873
ARIMA	100%	(0,1,0)	0,11747	(1,1,0)	0,46041	(0,1,1)	11,00507
ARIMA	125%	(0,1,0)	0,11747	(1,1,0)	0,46291	(0,1,1)	9,86434
ARIMA	150%	(0,1,0)	0,11747	(1,1,0)	0,46386	(0,1,1)	8,53600
ARIMA	175%	(0,1,0)	0,11747	(1,1,0)	0,46328	(0,1,2)	6,84328
ARIMA	200%	(2,1,0)	0,06377	(1,1,0)	0,46683	(0,1,1)	6,12750
SARIMA	100%	(0,1,0)(0,0,0)	0,11747	(1,1,0)(1,0,0)	0,58739	(0,1,1)(0,0,0)	11,00507
SARIMA	125%	(0,1,0)(0,0,0)	0,11747	(1,1,0)(0,0,0)	0,46291	(0,1,1)(0,0,0)	9,86434
SARIMA	150%	(0,1,0)(0,0,0)	0,11747	(1,1,0)(0,0,0)	0,46386	(0,1,1)(0,0,0)	8,53600
SARIMA	175%	(0,1,0)(0,0,0)	0,11747	(1,1,0)(0,0,0)	0,46328	(0,1,2)(0,0,0)	6,84328
SARIMA	200%	(2,1,0)(0,0,0)	0,06377	(1,1,0)(0,0,0)	0,46683	(1,1,0)(0,0,0)	6,12750

FONTE: O autor (2024).

4.2.2 Previsões


Após a obtenção do modelo adequado para cada cenário, fez-se a previsão do preço da gasolina para os próximos 6, 12 e 18 meses; seguindo os modelos e base de treinos selecionados em azul na Tabela 8.

Os resultados obtidos serão detalhados nas seções seguintes.

4.2.2.1 Previsão preço médio da gasolina no Brasil – 6 meses

Para o primeiro período de previsão de 6 meses, abrangendo 12 observações, selecionou-se o modelo de Médias Móveis, com uma base de treino de 8 meses. A Figura 10 representa os valores da base histórica utilizada para treinar o modelo. No eixo X estão dispostos os períodos de 15 de maio de 2023 até 31 de dezembro de 2023 (16 observações), e o eixo Y representa a média quinzenal do preço da gasolina no Brasil.

FIGURA 10 - PERÍODO PARA TREINO DE PREVISÃO DE 6 MESES DO PREÇO DA GASOLINA NO BRASIL



FONTE: O autor (2024).

Com este período, aplicou-se o teste ADF (*Augmented Dickey-Fuller*) para verificar se a série era estacionária (XAVIER, 2016). Uma vez que o resultado foi positivo, não realizou-se o processo de diferenciação (Figura 11).

FIGURA 11 - TESTE ESTACIONÁRIO PARA A BASE TREINO – PREVISÃO 6 MESES

```
def teste_ADF(série):
    # Realiza o teste ADF
    adf_resultado = adfuller(série)

    # Imprime os resultados do teste
    print(f'Estatística de Teste = {adf_resultado[0]}')
    print(f'p-valor = {adf_resultado[1]}')
    print('Valores Críticos:')
    for chave, valor in adf_resultado[4].items():
        print(f'    {chave}: {valor}')

    # Determina se a série é estacionária com base no p-valor
    if adf_resultado[1] < 0.05:
        print('Resultado: Série Estacionária')
    else:
        print('Resultado: Série Não Estacionária')
```

```
teste_ADF(dt_historico)

Estatística de Teste = -8.266105303794774
p-valor = 4.933560989071098e-13
Valores Críticos:
1%: -4.473135048010974
5%: -3.28988060356653
10%: -2.7723823456790124
Resultado: Série Estacionária
```

FONTE: O autor (2024) com base em ASSAOKA (2024).

Dessa maneira, aplicou-se o modelo de previsão com Médias Móveis ($q=1$) por meio da biblioteca *statsmodels.tsa.arima.model*, igualando os parâmetros de p e d a zero e mantendo o parâmetro q com o valor de 1 (Figura 12).

FIGURA 12 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR MÉDIAS MÓVEIS

```
modelo_MA = ARIMA(dt_historico, order = (0, 1, 0)) # O modelo ARIMA(0, 1, 0) foi o que apresentou o menor AIC
resultado_MA = modelo_MA.fit() # Treinando o modelo
print(resultado_MA.summary()) # Sumário do modelo
```

```
SARIMAX Results
```

Dep. Variable:	y	No. Observations:	16
Model:	ARIMA(0, 1, 0)	Log Likelihood	9.087
Date:	Tue, 14 May 2024	AIC	-16.174
Time:	22:15:19	BIC	-15.466
Sample:	0	HQIC	-16.181
	- 16		
Covariance Type:	opg		

```
=====
```

	coef	std err	z	P> z	[0.025	0.975]
-----	-----	-----	-----	-----	-----	-----
sigma2	0.0174	0.004	3.897	0.000	0.009	0.026
-----	-----	-----	-----	-----	-----	-----

Ljung-Box (L1) (Q):	0.71	Jarque-Bera (JB):	6.99
Prob(Q):	0.40	Prob(JB):	0.03
Heteroskedasticity (H):	0.09	Skew:	1.46
Prob(H) (two-sided):	0.02	Kurtosis:	4.63

```
=====
```

FONTE: O autor (2024) com base em ASSAOKA (2024).

Como resultado, tem-se a Tabela 9, onde estão dispostos os valores médios em reais do preço da gasolina para as 12 subsequentes observações da base de dados.


TABELA 9 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 6 MESES

Quinzena	Preço previsto	Quinzena	Preço previsto
2024-01-15	R\$ 5,65	2024-04-15	R\$ 5,65
2024-01-31	R\$ 5,65	2024-04-30	R\$ 5,65
2024-02-15	R\$ 5,65	2024-05-15	R\$ 5,65
2024-02-29	R\$ 5,65	2024-05-31	R\$ 5,65
2024-03-15	R\$ 5,65	2024-06-15	R\$ 5,65
2024-03-31	R\$ 5,65	2024-06-30	R\$ 5,65

FONTE: O autor (2024).

Assim, plotou-se o gráfico contemplando o período histórico e previsto do preço médio da gasolina (Figura 13), onde a linha azul representa o período histórico e a alaranjada indica os valores futuros do combustível. No eixo X estão dispostos os períodos de avaliação e no eixo Y, o valor médio em reais.

FIGURA 13 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 6 MESES (JAN'24-JUN'24)




FONTE: O autor (2024).

Como resultado, tem-se uma tendência linear constante para o preço médio da gasolina no Brasil no período de 6 meses.

4.2.2.2 Previsão preço médio da gasolina no Brasil – 12 meses

Para o período de previsão de 12 meses, abrangendo 24 observações, selecionou-se o modelo Autorregressivo (AR), com uma base de treino de 24 meses. A Figura 14 representa os valores da base histórica utilizada para treinar o modelo. No eixo X estão dispostos os períodos de 15 de janeiro de 2022 até 31 de dezembro de 2023 (48 observações), e o eixo Y representa a média quinzenal do preço da gasolina no Brasil.

FIGURA 14 - PERÍODO PARA TREINO DE PREVISÃO DE 12 MESES DO PREÇO DA GASOLINA NO BRASIL



FONTE: O autor (2024).

Com este período, verificou-se a estacionariedade da série por meio do teste ADF (*Augmented Dickey-Fuller*) (XAVIER, 2016), sendo necessário diferenciá-la apenas uma vez para que se tornasse estacionária, indicando uma ordem $d=1$ (Figura 15).

FIGURA 15 - TESTE ESTACIONÁRIO E DIFERENCIAÇÃO PARA A BASE TREINO – PREVISÃO 12 MESES

```
def teste_ADF(série):
    # Realiza o teste ADF
    adf_resultado = adfuller(série)

    # Imprime os resultados do teste
    print(f'Estatística de Teste = {adf_resultado[0]}')
    print(f'p-valor = {adf_resultado[1]}')
    print('Valores Críticos:')
    for chave, valor in adf_resultado[4].items():
        print(f'    {chave}: {valor}')

    # Determina se a série é estacionária com base no p-valor
    if adf_resultado[1] < 0.05:
        print('Resultado: Série Estacionária')
    else:
        print('Resultado: Série Não Estacionária')
```

```
teste_ADF(dt_historico)
```

```
Estatística de Teste = -1.6330642796245147
p-valor = 0.4658871574720991
Valores Críticos:
    1%: -3.5812576580093696
    5%: -2.9267849124681518
    10%: -2.6015409829867675
Resultado: Série Não Estacionária
```

```
# Diferenciação 1 da série temporal
dt_historico = dt_historico.diff()
dt_historico.dropna(inplace=True)
```


```
#Validação série após a diferenciação
teste_ADF(dt_historico)
```

```
Estatística de Teste = -4.3936515369402995
p-valor = 0.0003046065234229306
Valores Críticos:
    1%: -3.5812576580093696
    5%: -2.9267849124681518
    10%: -2.6015409829867675
Resultado: Série Estacionária
```

FONTE: O autor (2024) com base em ASSAOKA (2024).

Dessa maneira, aplicou-se o método AR ($p=1$) por meio da biblioteca *statsmodels.tsa.arima.model*, igualando os parâmetros de q a zero, e o parâmetro $d=1$, automatizando a diferenciação da série com o modelo (Figura 16).

FIGURA 16 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR AUTORREGRESSÃO



FONTE: O autor (2024) com base em ASSAOKA (2024).

Como resultado, tem-se a Tabela 10, onde estão dispostos os valores médios em reais do preço da gasolina para as 24 subseqüentes observações da base de dados.


TABELA 10 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 12 MESES

Quinzena	Preço previsto	Quinzena	Preço previsto
2024-01-15	R\$ 5,66	2024-07-15	R\$ 5,81
2024-01-31	R\$ 5,68	2024-07-31	R\$ 5,82
2024-02-15	R\$ 5,70	2024-08-15	R\$ 5,83
2024-02-29	R\$ 5,71	2024-08-31	R\$ 5,83
2024-03-15	R\$ 5,73	2024-09-15	R\$ 5,84
2024-03-31	R\$ 5,74	2024-09-30	R\$ 5,85
2024-04-15	R\$ 5,75	2024-10-15	R\$ 5,85
2024-04-30	R\$ 5,76	2024-10-31	R\$ 5,86
2024-05-15	R\$ 5,77	2024-11-15	R\$ 5,86
2024-05-31	R\$ 5,78	2024-11-30	R\$ 5,87
2024-06-15	R\$ 5,79	2024-12-15	R\$ 5,87
2024-06-30	R\$ 5,80	2024-12-31	R\$ 5,88

FONTE: O autor (2024).

Assim, plotou-se o gráfico contemplando o período histórico e previsto do preço médio da gasolina (Figura 17), onde a linha azul representa o período histórico e a alaranjada indica os valores futuros do combustível. No eixo X estão dispostos os períodos de avaliação e no eixo Y, o valor médio em reais.

FIGURA 17 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 12 MESES (JAN'24-DEZ'24)



FONTE: O autor (2024).


Como resultado, tem-se uma tendência crescente para o preço médio da gasolina no Brasil no período de 12 meses.

4.2.2.3 Previsão preço médio da gasolina no Brasil – 18 meses

Para o período de previsão de 18 meses, abrangendo 36 observações, selecionou-se o modelo Autorregressivo (AR), com uma base de treino de 36 meses. A Figura 18 representa os valores da base histórica utilizada para treinar o modelo. No eixo X estão dispostos os períodos de 15 de janeiro de 2021 até 31 de dezembro de 2023 (72 observações), e o eixo Y representa a média quinzenal do preço da gasolina no Brasil.

FIGURA 18 - PERÍODO PARA TREINO DE PREVISÃO DE 18 MESES DO PREÇO DA GASOLINA NO BRASIL

Série histórica para treino (36 meses) - Previsão do preço da gasolina no Brasil para os próximos 18 meses



FONTE: O autor (2024).

Com este período, verificou-se que a série não era estacionária por meio do teste ADF (*Augmented Dickey-Fuller*) (XAVIER, 2016), sendo necessário diferenciá-la apenas uma vez para que se tornasse estacionária, indicando uma ordem $d=1$ (Figura 19).

FIGURA 19 - TESTE ESTACIONÁRIO E DIFERENCIAÇÃO PARA A BASE TREINO – PREVISÃO 18 MESES

```
def teste_ADF(série):
    # Realiza o teste ADF
    adf_resultado = adfuller(série)

    # Imprime os resultados do teste
    print(f'Estatística de Teste = {adf_resultado[0]}')
    print(f'p-valor = {adf_resultado[1]}')
    print('Valores Críticos:')
    for chave, valor in adf_resultado[4].items():
        print(f'    {chave}: {valor}')

    # Determina se a série é estacionária com base no p-valor
    if adf_resultado[1] < 0.05:
        print('Resultado: Série Estacionária')
    else:
        print('Resultado: Série Não Estacionária')
```

```
teste_ADF(dt_historico)
```

```
Estatística de Teste = -2.102457785951019
p-valor = 0.24352746261748798
Valores Críticos:
    1%: -3.5274258688046647
    5%: -2.903810816326531
    10%: -2.5893204081632653
Resultado: Série Não Estacionária
```

```
# Diferenciação 1 da série temporal
dt_historico = dt_historico.diff()
dt_historico.dropna(inplace=True)
```


```
#Validação série após a diferenciação
teste_ADF(dt_historico)
```

```
Estatística de Teste = -5.1656431189160985
p-valor = 1.0328895528651382e-05
Valores Críticos:
    1%: -3.5274258688046647
    5%: -2.903810816326531
    10%: -2.5893204081632653
Resultado: Série Estacionária
```

FONTE: O autor (2024) com base em ASSAOKA (2024).

Dessa maneira, aplicou-se o modelo AR ($p=1$) por meio da biblioteca *statsmodels.tsa.arima.model*, igualando os parâmetros de q a zero, e o parâmetro $d=1$, automatizando a diferenciação da série com o modelo (Figura 20).

FIGURA 20 - UTILIZAÇÃO DO MODELO ARIMA PARA PREVISÃO POR AUTORREGRESSÃO



FONTE: O autor (2024) com base em ASSAOKA (2024).

Como resultado, tem-se a Tabela 11, onde estão dispostos os valores médios em reais do preço da gasolina para as 36 subseqüentes observações da base de dados.

TABELA 11 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 18 MESES

(continua)

Quinzena	Preço previsto	Quinzena	Preço previsto
2024-01-15	R\$ 5,66	2024-10-15	R\$ 5,85
2024-01-31	R\$ 5,68	2024-10-31	R\$ 5,86
2024-02-15	R\$ 5,70	2024-11-15	R\$ 5,86
2024-02-29	R\$ 5,71	2024-11-30	R\$ 5,87
2024-03-15	R\$ 5,73	2024-12-15	R\$ 5,87
2024-03-31	R\$ 5,74	2024-12-31	R\$ 5,88
2024-04-15	R\$ 5,75	2025-01-15	R\$ 5,88
2024-04-30	R\$ 5,76	2025-01-31	R\$ 5,56
2024-05-15	R\$ 5,77	2025-02-15	R\$ 5,56
2024-05-31	R\$ 5,78	2025-02-28	R\$ 5,56
2024-06-15	R\$ 5,79	2025-03-15	R\$ 5,56
2024-06-30	R\$ 5,80	2025-03-31	R\$ 5,56
2024-07-15	R\$ 5,81	2025-04-15	R\$ 5,55

TABELA 11 - RESULTADO DA PREVISÃO POR MÉDIAS MÓVEIS PARA O PERÍODO DE 18 MESES


(conclusão)

Quinzena	Preço previsto	Quinzena	Preço previsto
2024-07-31	R\$ 5,82	2025-04-30	R\$ 5,55
2024-08-15	R\$ 5,83	2025-05-15	R\$ 5,55
2024-08-31	R\$ 5,83	2025-05-31	R\$ 5,55
2024-09-15	R\$ 5,84	2025-06-15	R\$ 5,55
2024-09-30	R\$ 5,85	2025-06-30	R\$ 5,55

FONTE: O autor (2024).

Assim, plotou-se o gráfico contemplando o período histórico e previsto do preço médio da gasolina (Figura 21), onde a linha azul representa o período histórico e a alaranjada indica os valores futuros do combustível. No eixo X estão dispostos os períodos de avaliação e no eixo Y, o valor médio em reais.

FIGURA 21 - PREVISÃO DO PREÇO MÉDIO DA GASOLINA NO BRASIL PARA 18 MESES (JAN'24-JUN'25)



FONTE: O autor (2024).

Como resultado, tem-se uma tendência decrescente para o preço médio da gasolina no Brasil no período de 18 meses.

4.3 ELEMENTOS EXTERNOS DE IMPACTO NA PRECIFICAÇÃO DA GASOLINA NO BRASIL

Com o objetivo de encontrar os períodos com maior oscilação positiva e negativa no preço médio da gasolina no Brasil, entre janeiro de 2013 até dezembro de 2023, selecionou-se o modelo, a base de treino e teste que obteve o menor Erro Quadrático Médio (EQM) apresentado na seção anterior. Assim, utilizou-se a modelagem de Médias Móveis (MA) com parâmetro $q=1$, sendo 6 (seis) meses de dados para teste e 8 (oito) para treino.

Com isto, aplicou-se um algoritmo utilizando a função *AUTOARIMA* da biblioteca *pmdarima* no *python*, pois possui integrada o teste de estacionariedade e a diferenciação da série, aplicando parâmetros de $q = 1$ e d variável entre zero e dois (diferenciação apenas nas séries não estacionárias), com o objetivo de gerar uma previsão, EQM e variação entre o valor médio real e o previsto para cada ponto da série (Figura 22).

FIGURA 22 - ALGORITMO AUTOARIMA PARA DETECTAR OSCILAÇÕES NA SÉRIE TEMPORAL

```
for n in dt_list:
    dt_train = dt_3.loc[min(dt_3.index):min(dt_3.index) + (n+16)]
    dt_train = dt_train.set_index('Data')
    dt_test = dt_3.loc[min(dt_3.index) + (n+(17)):min(dt_3.index) + (n+16+12)]
    dt_test = dt_test.set_index('Data')

    arima_model = auto_arima(dt_train, start_p=0, d=1, start_q=1,
                             max_p=0, max_d=2, max_q=1,
                             start_P=0, D=0, start_Q=0, max_P=5, max_D=2,
                             max_Q=5, m=12, seasonal=False,
                             stationary=False,
                             error_action='warn', trace=True,
                             suppress_warnings=True, stepwise=True,
                             random_state=20, n_fits=50)

    previsão = arima_model.predict(n_periods=12)
    #previsão = previsão.reset_index()

    media_previsto = previsão.mean()
    media_teste = dt_test.mean()
    variancia = np.round(media_teste/media_previsto,4)
    variancia_previsto = previsão.var()
    variancia_teste = dt_test.var()
    diferenças = dt_test - previsão

    eqm = mean_squared_error(dt_test, previsão)

    resumo = pd.DataFrame({'data' : min(dt_test.index),
                          'eqm' : eqm,
                          'variancia' : variancia
                          })

    resultado = resultado._append(resumo,ignore_index=True)
    print(resultado)
```

FONTE: O autor (2024).


Assim, tendo como base 20 observações com maiores e menores variâncias e maiores EQM, foi possível filtrar os períodos com oscilações, positiva e negativa, ao longo da série. Tais períodos estão descritos na Tabela 12 e representados graficamente na Figura 23.

TABELA 12 - PRINCIPAIS PERÍODOS DE OSCILAÇÃO POSITIVA E NEGATIVA NA SÉRIE TEMPORAL

Quinzena	Variação	EQM	Tendência
05/2020 – 06/2020	1,10	0,77	Positiva (aumento do preço)
10/2020 – 03/2021	1,13	0,49	Positiva (aumento do preço)
10/2018 – 12/2018	0,19	0,92	Negativa (redução do preço)
12/2019 – 04/2020	0,27	0,91	Negativa (redução do preço)
03/2022 – 06/2022	0,88	3,00	Negativa (redução do preço)

FONTE: O autor (2024).

FIGURA 23 - PRINCIPAIS PERÍODOS DE OSCILAÇÃO POSITIVA E NEGATIVA NA SÉRIE TEMPORAL (ILUSTRAÇÃO)



FONTE: O autor (2024).

Após a seleção de tais períodos, conduziu-se uma análise causal para compreender possíveis fatores externos à série que impulsionaram tais oscilações, como por exemplo, mudanças sociais, econômicas, políticas, entre outras.

4.3.1 Elementos externos de impacto na redução do preço da gasolina no Brasil

Em 2017, a Petrobrás alterou a política de precificação da gasolina, considerando o mercado internacional do barril de petróleo e também a taxa de câmbio do real (G1, 2018). Assim, a redução do preço do combustível no final de 2018 deu-se por conta da atenuação do custo de importação do barril (TREVIZAN, 2018).

Um dos principais fatores que afetou o preço do barril internacionalmente foi a desaceleração da economia chinesa, sendo em 2018 a menor da década (PRESSE, 2019). Com isto, a Opep (Organização de Países Exportadores de Petróleo) não conseguiu regular a quantidade de petróleo produzida de maneira assertiva, aumentando a oferta do produto mundialmente, enquanto a demanda reduziu mais do que o esperado (REUTERS, 2018).

Em suma, a redução do preço da gasolina no final de 2018 deu-se por tomada de decisão política chinesa de desaceleração econômica, desequilíbrio da oferta e demanda no mercado do combustível, e por fatores econômicos na precificação da gasolina no Brasil.

A queda no preço de gasolina no início de 2020 no Brasil, deu-se majoritariamente devido à pandemia do coronavírus, desestabilizando o mercado mundial do combustível com significativa redução de demanda (GUIMARÃES, 2020).

Outro fator de impacto neste período foi o reajuste da economia global após a crise entre os Estados Unidos e Irã em meados de 2019. A princípio, com a morte do líder da Guarda Revolucionária Iraniana, o preço internacional do petróleo elevou-se, e no início de 2020 tornou a estabilizar-se. Uma vez que a Petrobrás possui a política de não impactar a economia internacional do combustível, mas seguir seu preço global, tem-se a variação de preço do produto no país (PODER360, 2020)

Resumindo, a redução do preço da gasolina no início de 2020 deu-se pelo impacto de crises políticas internacionais, crises de saúde globais e pela abordagem econômica de petrolíferas no país.

O presidente em 2022 no Brasil fechou seu mandato de quatro anos com um aumento acumulado de 21% no preço da gasolina no país, devido ao aumento do preço do barril do petróleo, e a desvalorização do real frente ao dólar

(CARREGOSA, 2023). Em meados de 2022, adotou-se a lei do teto de ICMS (Imposto sobre a Circulação de Mercadorias e Serviços) para combustíveis, reduzindo em alguns estados de 30% para 18% (CARREGORA, 2023; MORENO, 2022).

Assim, conclui-se que a redução do preço da gasolina no primeiro semestre de 2022 deu-se por estratégica política de ano de eleição presidencial, e aplicação de mudanças judiciais com consequência na economia do país.

4.3.2 Elementos externos de impacto no aumento do preço da gasolina no Brasil

Em 2020, a pandemia do coronavírus afetou significativamente a economia mundial, reduzindo a demanda de petróleo mundialmente. Assim, a Opep (Organização de Países Exportadores de Petróleo) tomou a decisão de reduzir a quantidade de barris disponíveis, reequilibrando o mercado. Como consequência, aumenta-se novamente o preço da gasolina em resposta a redução do seu valor nos meses anteriores (CNN, 2020).

Em suma, o aumento do preço da gasolina em 2020 foi consequência da estabilização do mercado internacional do produto pós início da pandemia do coronavírus, assim como também, reflexo da política de precificação das petroleiras brasileiras.

Por fim, o aumento consecutivo do preço da gasolina no ano de 2021 deu-se por questões políticas internas e externas ao Brasil. Segundo o IBGE, o presidente da época acumulou em seu mandato de 4 anos, uma inflação de quase 24%, ocasionando uma alta de 64% no preço do combustível frente aos presidentes antecessores (MOTTA, 2022). Além disto, a guerra entre a Rússia e a Ucrânia causou instabilidade econômica, elevando o preço do barril do petróleo no exterior (MOTTA, 2022), afetando o Brasil devido a Política de Preço de Paridade Internacional (PPI) (PEREIRA, 2021).

Outro fator impactante é a vacinação contra o coronavírus, a qual possibilitou o retorno gradativo das atividades nos países, aumentando a demanda da gasolina, desestabilizando o mercado internacional (MOTA, 2021).

Em resumo, o aumento do preço do combustível no ano de 2021 ocorreu devido instabilidade econômica nacional, guerras internacionais e a retomada das atividades corriqueiras pós pandemia.


5 CONSIDERAÇÕES FINAIS

Este trabalho teve como principal finalidade determinar qual modelo de previsão, com abordagem autorregressiva e de médias móveis, é mais assertivo para a previsão de séries temporais e análise das oscilações no preço da gasolina no Brasil. A partir da análise e modelagem desenvolvidas, conclui-se que os objetivos estabelecidos foram atingidos com sucesso.

Como principais conclusões, entende-se que o método Autorregressivo (AR), em conjunto com abordagens de estacionariedade de séries temporais (como a diferenciação), é o mais assertivo para prever o preço da gasolina a médio e longo prazo no Brasil (12 e 18 meses). Por outro lado, o método de Médias Móveis (MA), novamente, em conjunto com modelos de estacionariedade, é mais assertivo para previsão do preço do combustível a curto prazo (6 meses), assim como também para avaliar suas oscilações ao longo da década. Ou seja, como ambos necessitam do processo de diferenciação, a utilização de modelo Autorregressivo Integrado de Médias Móveis (ARIMA), pode beneficiar a condução da análise, uma vez que automatiza a diferenciação das séries.

Como resumo visual de tais conclusões, desenvolveu-se uma visão sistêmica dos processos e principais resultados obtidos ao longo deste trabalho (Figura 24).

FIGURA 24 - RESUMO GRÁFICO DOS PRINCIPAIS PROCESSOS E RESULTADOS



FONTE: O autor (2024).

O primeiro quadro apresenta os resultados da decomposição aditiva da série temporal analisada. Tem-se uma tendência positiva, porém não linear, apresentando oscilações ao longo do período. Além disto, detectou-se uma sazonalidade anual ao longo da série, e uma porção, denominada resíduo, que é composta pela aleatoriedade externa à tendência e sazonalidade da série. Ou seja, indica que possíveis fatores externos aos dados impactam suas oscilações, tais como mudanças sociais, políticas, econômicas, de saúde, ambientais, entre outras.

O segundo quadro representa os modelos que obtiveram menores os critérios de Akaike (AIC) e quadrático médio (EQM), para cada período de previsão analisado (6, 12 e 18 meses). Como consequência, é possível compreender que, quanto maior a base histórica utilizada para treinar e testar os modelos, mais semelhantes são os parâmetros (p , q e d).

O quadrado seguinte, apresenta em alaranjado o modelo de previsão de 6 meses do preço da gasolina no Brasil, com a abordagem de mesma cor, ressaltada no quadro acima (8 meses de base histórica com ordem $p = 0$, $q = 1$ e $d = 1$); da mesma forma em roxo para a previsão de 12 meses, e em verde para a de 18 meses.

Como conclusão, tem-se que o modelo de MA fornece uma tendência linear devido a sua abordagem matemática, enquanto os modelos AR conseguem detectar flutuações no valor da série prevista. Além disto, mesmo que a previsão de 12 e 18 meses possuam a mesma modelagem (1,0,1), é possível detectar que a base histórica de diferente tamanho não chegou a influenciar no resultado final, uma vez que ambas as previsões de preço coincidem os valores.

Por fim, o último quadro apresenta a análise de oscilações da série, contemplando os 3 principais períodos de aumento (1º semestre 2020 e o ano de 2021) e os 3 de redução (final de 2018, início de 2020 e 2022) no preço da gasolina no Brasil.

Com a análise causal desses períodos, compreende-se que crises econômicas, pandemias e guerras desestabilizam o mercado do petróleo, fazendo com que haja um aumento na oferta e redução na demanda, reduzindo o preço do barril globalmente. Por outro lado, após a estabilização da oferta, por meio de estratégias da Opep (Organização dos Países Exportadores de Petróleo), o mercado tende a se equilibrar novamente, aumentando o preço do combustível. Além disso, a política de precificação das petroleiras locais influencia a ocorrência das oscilações,

por contabilizar o preço internacional do barril de petróleo, assim como o valor da moeda de câmbio. Por fim, a aplicação de novas leis para corroborar estratégias políticas locais também impactam significativamente o preço do produto, principalmente em época eleitoral.

A principal vantagem desta abordagem é a comparação entre diferentes métodos, bases de testes e de treinos, abrangendo uma avaliação extensa sobre a série analisada, para definir o método mais assertivo para a predição do preço do combustível. No entanto, uma potencial fraqueza é a utilização da média do valor do preço da gasolina no Brasil, podendo variar de acordo com o estado ou a cidade no país.

Para tornar essa abordagem mais robusta, seria adequado realizá-la por cidade, estado ou região, fornecendo um valor de previsão do preço para cada localidade, de acordo com suas singularidades. Além disto, poderia também ser automatizada a captação de dados para a análise causal das oscilações do preço na série, por meio de *data scraping* ou outra técnica de coleta de dados na *web*.

REFERÊNCIAS

AGÊNCIA SENADO. Nova política de preços da Petrobras 'passou no teste', diz Prates. **Da Agência Senado**. 2023. Disponível em: <https://www12.senado.leg.br/noticias/materias/2023/08/16/nova-politica-de-precos-da-petrobras-passou-no-teste-diz-prates>. Acesso em: 13 mar. 2024.

AKRAMI, S. A.; EL-SHAFIE, A.; NASERI, M.; SANTOS, C. A. G. Análise de dados de precipitação usando modelo de média móvel (MA) e modelo inteligente wavelet multi-resolução para avaliação de ruído para melhorar a precisão da previsão. **Computação Neural e Aplicações**. 25 ed. 2014. p. 1853. DOI: <https://doi.org/10.1007/s00521-014-1675-0>. Disponível em: <https://link.springer.com/article/10.1007/s00521-014-1675-0>. Acesso em: 27 out. 2023.

ANDRADE, R. Os desafios para a consolidação dos veículos elétricos no Brasil. IPEA – Centro de Pesquisa em Ciência, Tecnologia e Sociedade. 2023. Disponível em: <https://www.ipea.gov.br/cts/pt/central-de-conteudo/artigos/artigos/360-os-desafios-para-consolidacao-dos-veiculos-eletricos-no-brasil>. Acesso em: 18 mar. 2024.

ANGELO, C. F.; ZWICKER, R.; FOUTO, N. M. M. D.; LUPPE, M. R. Séries temporais e redes neurais: uma análise comparativa de técnicas na previsão de vendas do varejo brasileiro. **Brazilian Business Review**, Espírito Santo. 8. ed. BBR, 2011. p. 1. DOI: <https://doi.org/10.15728/bbr.2011.8.2.1>. Disponível em: <https://bbronline.com.br/index.php/bbr/article/view/302>. Acesso em: 28 set. 2023.

ANP. Agência Nacional do Petróleo, Gás Natural e Biocombustíveis. Disponível em: <https://dados.gov.br/dados/organizacoes/visualizar/agencia-nacional-do-petroleo-gas-natural-e-biocombustiveis-anp>. Acesso em: 21 set. 2023.

ARAÚJO, R. P.; NETO, A. D. D. Rede neural de Elman aplicada na previsão de preços de combustíveis. **II Congresso Nacional de Engenharia de Petróleo, Gás Natural e Biocombustíveis**. 2. ed. 2016.

ARÊDES, A. F.; PEREIRA, M. W. G. Potencialidade da utilização de modelos de séries temporais na previsão do preço do trigo no estado do Paraná. **Revista de Economia Agrícola**, São Paulo. 55. ed. 2008. p. 63.

ASSAOKA, J. V. Previsão de dados pluviométricos com modelos clássicos. **GitHub**, 2024. Disponível em: https://github.com/Assaoka/Series_Temporais/tree/main/%5B2%5D%20Previs%C3%A3o%20de%20Dados%20Pluviometricos%20com%20Modelos%20Cl%C3%A1ssico. Acesso em: abr. de 2024.

BANDURA, E. ET AL. Applications of the ARIMA model for time series data analysis. **Applied Research & Agrotechnology**. 12. ed. 2020. p. 145.

BIASE, N. G.; SILVA, M. I. S. Ajuste de modelos de séries temporais com intervenção para prever consumo de gasolina no Brasil. **Sigmae**. 2. ed. Alfenas, 2012. p. 23.

BOUZADA, M. A. C. Aprendendo decomposição clássica: Tutorial para um método de análise de séries temporais. **ANPAD**, Rio de Janeiro. 2. ed. TAC, 2012. p. 1. Disponível em: https://arquivo.anpad.org.br/periodicos/arq_pdf/a_1320.pdf. Acesso em: 30 set. 2023.

BOX, G. E. P.; JENKINS, G. M. Time series analysis forecasting and control. San Francisco. **Holden-Day**. 1976. Edição revisada.

BRESSAN, A. A. Tomada de decisão em futuros agropecuários com modelos de previsão de séries temporais. **Finanças**. 3. ed. RAE electron, 2004. DOI: <https://doi.org/10.1590/S1676-56482004000100005>. Disponível em: <https://www.scielo.br/j/raeel/a/pyJSSHNTigMQdFhtFdnYNXJ/?lang=pt>. Acesso em: 15 set. 2023.

BRITO, F. B. S.; MONTEIRO, R. L. S. M.; GUEDES, E. F.; SANTOS, L. B. Etanol no Brasil: uma abordagem preditiva de preços. **International Symposium on Innovation and Technology**. 2018.

BRUGGEMANN, O. M.; PARPINELLI, M. A. Utilizando as abordagens quantitativa e qualitativa na produção do conhecimento. **Ver Esc Enferm USP**. SCIELO, 42 ed. 2008. p. 563. DOI: <https://doi.org/10.1590/S0080-62342008000300021>. Disponível em: <https://doi.org/10.1590/S0080-%2062342008000300021>. Acesso em: 15 set. 2023.

CAMPOS, R. J. Previsão de séries temporais com aplicações a séries de consumo de energia elétrica. **Universidade Federal de Minas Gerais**. 2008. Disponível em <https://repositorio.ufmg.br/bitstream/1843/BUOS-8CTETD/1/290m.pdf>. Acesso em: 23 set. 2023.

CARREGOSA, L. Preço da gasolina cai 25% em 2022, mas mantém alta sob Bolsonaro. **PODER360**, 2023. Disponível em <https://www.poder360.com.br/governo/preco-da-gasolina-cai-25-em-2022-mas-mantem-alta-sob-bolsonaro/#:~:text=Corte%20de%20impostos%20justifica%20a,por%20litro%20na%20m%C3%A9dia%20nacional&text=O%20pre%C3%A7o%20da%20gasolina%20acumulou,%2C%20G%C3%A1s%20Natural%20e%20Biocombust%C3%ADveis>. Acesso em: 27 mar. 2024.

CARTA CAPITAL. Inflação fica em 0,26% em setembro, influenciada pelo aumento da gasolina. **Carta Capital**. 2023. Disponível em: <https://www.cartacapital.com.br/economia/inflacao-fica-em-026-em-setembro-influenciada-pelo-aumento-da-gasolina/>. Acesso em: 05 abr. 2024.

CAS, C. G. Aplicação do modelo ARIMA para a previsão do preço da commodity milho. **Journal of Sustainable Production, Operations and System Management**.

13 ed. 2018. DOI: <https://doi.org/10.15675/gepros.v13i1.2040>. Disponível em: <https://revista.feb.unesp.br/gepros/article/view/2040>. Acesso em: 15 set. 2023.

CHECHI, L.; BAYER, F. M. Modelos univariados de séries temporais para previsão das temperaturas médias mensais em Erechim, RS. **Meteorologia e Climatologia Agrícola**. 16. ed. Revista Brasileira De Engenharia Agrícola E Ambiental, 2012. p. 1321. DOI: <https://doi.org/10.1590/S1415-43662012001200009>. Disponível em: <https://www.scielo.br/j/rbeaa/a/kwktRpvj3VXT584XmySD6Xf/?lang=pt>. Acesso em: 15 set. 2023.

CNN Brasil. Demanda por gasolina no Brasil em 2023 deve subir 2,5% e por etanol 5,4%, prevê StoneX. **CNN Brasil**. 2023. Disponível em: [https://www.cnnbrasil.com.br/economia/demanda-por-gasolina-no-brasil-em-2023-deve-subir-25-e-por-etanol-54-preve-stonex/#:~:text=StoneX%20%7C%20CNN%20Brasil-,Demanda%20por%20gasolina%20no%20Brasil%20em%202023%20deve%20subir%202,5%2C4%25%2C%20prev%C3%AA%20StoneX&text=A%20demanda%20por%20gasolina%20no,ter%C3%A7a%20feira%20\(25\)](https://www.cnnbrasil.com.br/economia/demanda-por-gasolina-no-brasil-em-2023-deve-subir-25-e-por-etanol-54-preve-stonex/#:~:text=StoneX%20%7C%20CNN%20Brasil-,Demanda%20por%20gasolina%20no%20Brasil%20em%202023%20deve%20subir%202,5%2C4%25%2C%20prev%C3%AA%20StoneX&text=A%20demanda%20por%20gasolina%20no,ter%C3%A7a%20feira%20(25)). Acesso em: 12 maio 2024.

CNN. Petrobras aumenta gasolina em 10%; no ano, queda acumulada ainda é de 24%. **CNN**, 2020. Disponível em: <https://www.cnnbrasil.com.br/economia/petrobras-aumenta-gasolina-em-10-no-ano-queda-acumulada-ainda-e-de-24/#:~:text=O%20aumento%20na%20gasolina%20vem,impactos%20da%20pandemia%20de%20coronav%C3%ADrus>. Acesso em: 10 maio 2024.

CRUZ, L. F. S. A. Enriquecendo a previsão de séries temporais usando informações textuais. **Universidade Federal de São Carlos**, São Paulo. 2021. Disponível em: <https://repositorio.ufscar.br/handle/ufscar/14258?show=full>. Acesso em: 15 set. 2023.

DIEHL, D. Formação do preço de etanol hidratado no Estado de São Paulo e sua relação com os mercados de açúcar e gasolina. **Escola Superior de Agricultura Luiz de Queiroz**, Piracicaba. 2021. DOI: <https://doi.org/10.11606/T.11.2012.tde-14082012-094235>. Disponível em: <https://www.teses.usp.br/teses/disponiveis/11/111132/tde-14082012-094235/pt-br.php>. Acesso em: 16 set. 2023.

EPE. EPE Publica a edição de abril de 2023 das perspectivas para o mercado brasileiro de combustíveis no curto prazo. **Empresa de Pesquisa Energética**. 2023. Disponível em: <https://www.epe.gov.br/pt/imprensa/noticias/epe-publica-a-edicao-de-abril-de-2023-das-perspectivas-para-o-mercado-brasileiro-de-combustiveis-no-curto-prazo>. Acesso em: 11 abr. 2024.

FERNANDES, M. B.; CARVALHO, T. C. Análise do comportamento do preço da gasolina para o mercado brasileiro. **Universidade Federal Rural do Seminário – UFERSA**. 2022.

FERREIRA, P. F. Estimação e seleção de caos determinístico em séries temporais financeiras. **Instituto Universitário de Lisboa**, Lisboa. 2014.

FILHO, I. J. R.; MARCACINI, R. M.; REZENDE, S. O. Previsão do preço futuro de commodities agrícolas: um estudo para enriquecer séries temporais. **Sociedade Brasileira de Automática**. 1 ed. 2021. DOI: <https://doi.org/10.20906/sbai.v1i1.2860>. Disponível em: https://www.sba.org.br/open_journal_systems/index.php/sbai/article/view/2860. Acesso em: 12 set. 2023.

FONSECA, M. A. Evolução do preço da gasolina no Brasil. **Universidade Federal de Pernambuco**, Pernambuco. Repositório Institucional UFRPE, 2023. Disponível em: <https://repository.ufrpe.br/handle/123456789/4635>. Acesso em: 15 maio 2024.

G1. Petrobrás anuncia nova redução no preço da gasolina; queda no mês chega a 19%. **G1**, 2018. Disponível em: <https://g1.globo.com/economia/noticia/2018/11/26/petrobras-anuncia-nova-reducao-no-preco-da-gasolina-queda-no-mes-chega-a-19.ghtml>. Acesso em: 27 maio 2024.

GUIMARÃES, D. Pandemia causa queda de 13% no preço da gasolina em 2020. **SUNO NOTÍCIAS**, 2020. Disponível em: <https://www.suno.com.br/noticias/pandemia-causa-queda-13-preco-gasolina-2020/>. Acesso em: 27 maio 2024.

IBPT – Instituto Brasileiro de Planejamento e Tributação. Entenda como funciona a política de preços da Petrobras e o impacto nos valores dos combustíveis. **IBPT**. 2023. Disponível em: <https://ibpt.com.br/entenda-como-funciona-a-politica-de-precos-da-petrobras-e-o-impacto-nos-valores-dos-combustiveis/>. Acesso em: 28 maio de 2024.

IVANOVSKI, Z.; MILENKOVSKI, A.; NARASANOV, Z. Time series forecasting using a moving average model for extrapolation of number of tourists. **UTMS Journal of Economics**. 9 ed. 2018. p. 121.

KASSOUF, A. L. Previsão de preços na pecuária de corte do estado de São Paulo. **Escola Superior de Agricultura Luiz e Queiroz**, Piracicaba. 1988. DOI: <https://doi.org/10.11606/D.11.2018.tde-20181127-154859>. Disponível em: <https://teses.usp.br/teses/disponiveis/11/11132/tde-20181127-154859/pt-br.php>. Acesso em: 20 set. 2023.

LIMA, R. C.; GÓIS, M.R.; ULISES, C. Previsão de preços futuros de Commodities agrícolas com diferenciações inteira e fracionária, e erros heteroscedásticos. **Rev Econ Sociol Rural**. 45 ed. 2007. p. 62. DOI: <https://doi.org/10.1590/S0103-20032007000300004>. Disponível em: <https://www.scielo.br/j/resr/a/vkSgM7My3GwLQysQYbYRSHr/?lang=pt>. Acesso em: 20 set. 2023.

MAKRIDAKIS, S.; ANDERSEN, A.; CARBONE, R.; FILDES, R.; HIBON, M.; LEWANDOWSKI, R.; NEWTON, J.; PARZEN, E.; WINKLER, R. The Accuracy of Extrapolation (Time Series) Methods: Results of a Forecasting Competition. **Journal of Forecasting**. 1. ed. 1982. p. 111

MARJOTTA-MAISTRO, M. C.; BARROS, G. S. C. Relações comerciais e de preços no mercado nacional de combustíveis. **Revista de Economia e Sociologia Rural**.

41. ed. 2003. p. 829. <https://doi.org/10.1590/S0103-20032003000400006>. Disponível em: <https://www.scielo.br/j/resr/a/hKysqyTpQPvfN88QccDmYdP/?lang=pt>. Acesso em: 30 maio 2024.

MELO, A. S. Três ensaios sobre os mercados de gasolina, etanol e açúcar no Brasil. **Universidade Federal de Pernambuco**. ATENA – Repositório Digital da UFPE. 2012. Disponível em: <https://repositorio.ufpe.br/handle/123456789/10274>. Acesso em: 19 set. 2023.

MORENO, T. Petrobras anuncia redução no preço da gasolina em R\$ 0,20 por litro. **Motor1.com**, 2022. Disponível em: <https://motor1.uol.com.br/news/599229/reducao-preco-gasolina-2022-petrobras/>. Acesso em: 28 maio 2024.

MOTA, C. V. Gasolina mais cara: 4 motivos para disparada de preços dos combustíveis. **BBC News Brasil**, 2021. Disponível em: <https://www.bbc.com/portuguese/brasil-58743202>. Acesso em: 28 maio 2024.

MOTTA, A. Governo Bolsonaro tem o menor e o maior preço da gasolina em 21 anos. **UOL ECONOMIA**, 2022. Disponível em: <https://economia.uol.com.br/noticias/redacao/2022/04/29/governo-bolsonaro-tem-o-menor-e-o-maior-preco-da-gasolina-em-20-anos.htm>. Acesso em: 28 maio 2024.

NOGUEIRA, I. C. Séries temporais como ferramenta de previsão de preços pagos ao produtor de cana-de-açúcar no Nordeste (AL, PB e PE). **Universidade Federal do Ceará**, Fortaleza. 2023.

OLIVEIRA, A. M. B.; CRISÓSTOMO, A. P. Previsão do volume exportado para a fruticultura brasileira via análise de séries temporais: uma abordagem ARIMA/GARCH. **Revista Científica Eletrônica de Engenharia de Produção**, Santa Catarina. 15. ed. Revista Produção Online, 2015. p. 553. DOI: <https://doi.org/10.14488/1676-1901.v15i2.1926>. Disponível em: <https://www.producaoonline.org.br/rpo/article/view/1926>. Acesso em: 15 set. 2023.

OXFORD LANGUAGES, 2024. Disponível em: https://www.google.com/search?q=significado+commodity&oq=significado+commodity&gs_lcrp=EgZjaHJvbWUyCQqAEEUYORiABDIKCAEQABgPGBYYHjIKCAIQABgPGBYYHjICAMQABgWGB4yCqgEEAAYDxqWGB4yCqgFEAAYDxqWGB4yDAqGEAAYChgPGBYYHjIKCAcQABgPGBYYHtIBCDQwNTRqMGo5qAIAAsAIB&sourceid=chrome&ie=UTF-8. Acesso em: 15 jun. 2024.

PEREIRA, T. Com novo reajuste, gasolina acumula alta de 73,4% em 2021. **Rede Brasil Atual (RBA)**, 2021. Disponível em: <https://www.redebrasilatual.com.br/economia/com-novo-reajuste-gasolina-acumula-alta-de-734-em-2020/>. Acesso em: 30 maio 2024.

PODER360. Petrobras reduz em 3% preço da gasolina e do diesel a partir desta 3ª feira. **PODER360**, 2020. Disponível em: <https://www.poder360.com.br/economia/petrobras-reduz-em-3-preco-da-gasolina-e-do-diesel-a-partir-desta-3a-feira/>. Acesso em: 30 maio 2024.

PRAUCHNER, M. J.; BRANDÃO, R. D.; FREITAS JÚNIOR, A. M.; OLIVEIRA, S. C. Combustíveis derivados do petróleo: obtenção, propriedades e uso. **Revista Virtual de Química**. 15 ed. 2022. p. 43. DOI: <http://dx.doi.org/10.21577/1984-6835.20220073>. Disponível em: <https://rvq.sbq.org.br/pdf/v15n1a05>. Acesso em: 15 set. 2023.

PRESSE, F. Crescimento da economia da China em 2018 deve ser o mais baixo em quase 30 anos. **G1**, 2019. Disponível em: <https://g1.globo.com/economia/noticia/2019/01/18/crescimento-da-economia-da-china-em-2018-deve-ser-o-mais-baixo-em-quase-30-anos.ghtml>. Acesso em: 30 maio 2024.

PUCRS – Pontifícia Universidade Católica do Rio Grande do Sul. Taxação da gasolina: saiba mais sobre as mudanças e os impactos no consumidor. **PUCRS**, Rio Grande do Sul. 2023. Disponível em: <https://www.pucrs.br/blog/taxacao-da-gasolina-saiba-mais-sobre-as-mudancas-e-o-impacto-no-consumidor/#:~:text=Fatores%20que%20influenciam%20o%20pre%C3%A7o,pre%C3%A7o%20do%20etanol%20e%20impostos>. Acesso em: 30 maio 2024

REUTERS. Preços do petróleo desabam 8% para o menor nível em mais de 1 ano. **G1**, 2018. Disponível em: <https://g1.globo.com/economia/noticia/2018/11/23/precos-do-petroleo-caem-para-minima-em-2018-apesar-de-planos-da-opec-por-cortes-de-producao.ghtml>. Acesso em: 30 maio 2024.

SANTOS JUNIOR, A. C. R. Análise comparativa de modelos estatísticos para previsão de demanda de gasolina no Brasil. **TEP – Trabalhos de Conclusão de Curso** – Niterói, Rio de Janeiro. 2018.

SANTOS, C. A.; LIMA, A. M. M.; FARIAS, M. H. C. S.; AIRES, U. R. V. SERRÃO, E. A. O. Análise estatística da não estacionariedade de séries temporais de vazão máxima anual diária na bacia hidrográfica do Rio Pardo Holos. **Instituto Federal de Educação, Ciência e Tecnologia do Rio Grande do Norte**, Natal. 7. ed. HOLOS, 2016. p. 179.

SANTOS, J. A. A.; CHAUCOSKI, Y. Previsão de preços de ovos, no estado do Paraná, por meio de modelos SARIMA e PROPHET. **Revista Cereus**. 14. ed. 2022. p. 234.

SANTOS, J. A. A.; SANDMANN, A.; HLENKA, V.; HELLMAN, L.; HALLAL, R.; SANTOS, C. O. Previsão do preço de milho: uma comparação entre os modelos SARIMA e LSTM. **Peer Review**. 5 ed. 2023. DOI: <https://doi.org/10.53660/952.prw2533>. Disponível em: <https://peerw.org/index.php/journals/article/view/952>. Acesso em: 15 set. 2023.

SATO, R. C. Gerenciamento de doenças utilizando séries temporais como o modelo ARIMA. **Revendo Ciências Básicas**, São Paulo. 11. ed. Einstein, 2013. DOI: <https://doi.org/10.1590/S1679-45082013000100024>. Disponível em: <https://www.scielo.br/j/eins/a/XqhY6VzmzbyZ9yRxLYzjCct/?lang=pt>. Acesso em: 20 set 2023.

SERRA, F. A. R.; FERREIRA, M. P. Cuidados a tomar nos artigos com pesquisa qualitativa. **Revista Ibero-Americana de Estratégia**. 15 ed. 2016. p. 1. DOI: <https://doi.org/10.5585/ijsm.v15i4.2493>. Disponível em: <https://periodicos.uninove.br/riae/article/view/15661>. Acesso em: 20 set. 2023.

SILVA, H. J. F.; LUCIO, P. S.; BROWN, F. Análise mensal, sazonal e interanual da evapotranspiração potencial para o leste do estado do Acre, Brasil. **Ciência e Natura**, Santa Maria. 38. ed. Revista do Centro de Ciências Naturais e Exatas. DOI: [10.5902/2179460X15881](https://doi.org/10.5902/2179460X15881). Disponível em: https://www.researchgate.net/publication/301247166_ANALISE_MENSAL_SAZONAL_E_INTERANUAL_DA_EVAPOTRANSPIRACAO_POTENCIAL_PARA_O_LESTE_DO_ESTADO_DO_ACRE_BRASIL. Acesso em: 15 set. 2023.

SILVA, M. C.; SILVA, J. D. G. Metodologia Científica para as Ciências Sociais Aplicadas: Análises Críticas sobre Métodos e Tipologias de Pesquisas e Destaque de Contribuições de Marx, Weber e Durkheim. **Revista Científica Hermes**. 13 ed. 2015. p. 159. DOI: <https://doi.org/10.21710/rch.v13i0.167>. Disponível em: <https://revistahermes.com.br/index.php/hermes1/article/view/167>. Acesso em: 15 set. 2023.

SILVA, M. I. S.; GUIMARÃES, E. C.; TAVARES, M. Previsão da temperatura média mensal de Uberlândia, MG, com modelos de séries temporais. **Meteorologia e Climatologia Agrícola**. 12. ed. Revista Brasileira de Engenharia Agrícola e Ambiental, 2008. p. 480. DOI: <https://doi.org/10.1590/S1415-43662008000500006>. Disponível em: <https://www.scielo.br/j/rbeaa/a/9BR9BfCSCRsw4wBMnFN6tJP/?lang=pt>. Acesso em: 14 set. 2023.

SILVA, M. M. Agrupamento de séries temporais utilizando decomposição de componentes estocásticos e determinísticos. **Universidade Federal da Bahia**, Bahia. 2018.

TAVARES, N. G.; VERALDO JUNIOR, L. G.; DOROTEA, R. S.; BORGES, J. E. S.; ZANIN, M. A. Aplicação de métodos para a previsão de demanda em um posto de gasolina no Vale do Paraíba. **XLI Encontro Nacional de Engenharia de Produção**, Paraná. 2021.

TIBULO, C.; TIBULO, V. C. Previsão do preço do milho, através de séries temporais. **Scientia Plena**. 10. ed. 2014.

TOMAZELLI, I.; GARCIA, N.; BRANT, D. Governo vai taxar exportação de petróleo para compensar retomada parcial de tributos sobre combustíveis. **Folha de São Paulo**, São Paulo. 2023. Disponível em: <https://www1.folha.uol.com.br/mercado/2023/02/governo-vai-taxar-exportacoes-de-petroleo-para-compensar-retomada-parcial-de-tributos-sobre-combustiveis.shtml>. Acesso em: 30 maio 2024.

TREVIZAN, K. Preço da gasolina para o consumidor final cai menos que nas refinarias em novembro. **G1**, 2018. Disponível em: <https://g1.globo.com/economia/noticia/2018/11/30/preco-da-gasolina-para-o->

[consumidor-final-cai-menos-que-nas-refinarias-em-novembro.ghml](#). Acesso em: 30 maio 2024.

XAVIER, J. M. N. Análise e previsão de séries temporais com modelos ARIMA e análise espectral singular. **Universidade Aberta**. 2016. Disponível em: https://repositorioaberto.uab.pt/bitstream/10400.2/5873/1/Disserta%c3%a7%c3%a3o_Jorge.Xavier_%201104916.pdf. Acesso em: 28 set. 2023.