



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS AGRÁRIAS
DEPARTAMENTO DE ECONOMIA AGRÍCOLA
CURSO DE GRADUAÇÃO EM AGRONOMIA

IGOR CLÁUDIO NOGUEIRA

**SÉRIES TEMPORAIS COMO FERRAMENTA DE PREVISÃO DE PREÇOS PAGOS
AO PRODUTOR DE CANA-DE-AÇUCAR NO NORDESTE (AL, PB E PE).**

FORTALEZA

2023

IGOR CLÁUDIO NOGUEIRA

SÉRIES TEMPORAIS COMO FERRAMENTA DE PREVISÃO DE PREÇOS PAGOS AO
PRODUTOR DE CANA-DE-AÇUCAR NO NORDESTE (AL, PB e PE).

Trabalho de conclusão de curso apresentado ao
Curso de Graduação em Agronomia do Centro
de Ciências Agrárias da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Agronomia.

Orientador: Prof. Dr. Vitor Hugo Miro Couto
Silva.

FORTALEZA

2023

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas
Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

N712s Nogueira, Igor Cláudio.
Séries temporais como ferramenta de previsão de preços pagos ao produtor de cana-de-açúcar no Nordeste (AL, PB e PE) / Igor Cláudio Nogueira. – 2023.
34 f. : il. color.

Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Centro de Ciências Agrárias, Curso de Agronomia, Fortaleza, 2023.
Orientação: Prof. Dr. Vitor Hugo Miro Couto Silva.

1. Séries temporais. 2. Previsão de preços. 3. Cana-de-açúcar. 4. Estacionariedade. I. Título.
CDD 630

IGOR CLÁUDIO NOGUEIRA

SÉRIES TEMPORAIS COMO FERRAMENTA DE PREVISÃO DE PREÇOS PAGOS AO
PRODUTOR DE CANA-DE-AÇUCAR NO NORDESTE (AL, PB e PE).

Trabalho de conclusão de curso apresentado ao
Curso de Graduação em Agronomia do Centro
de Ciências Agrárias da Universidade Federal
do Ceará, como requisito parcial à obtenção do
grau de bacharel em Agronomia.

Aprovada em: 20/06/2023.

BANCA EXAMINADORA

Prof. Dr. Vitor Hugo Miro Couto Silva (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Francisco José Tabosa
Universidade Federal do Ceará (UFC)

Ms. Marcos Paulo Mesquita da Cruz
Doutorando do Programa de Pós-Graduação em Economia Rural (UFC)

AGRADECIMENTOS

Agradeço a Deus por me conceder a oportunidade de cursar e concluir o curso, por todas as bênçãos derramadas sobre e mim e pelas inúmeras vezes que me sustentou.

À minha família, meu irmão Luan Claudio, minha irmã Lara Claudio e em especial minha mãe Teresa Neuma, por todo o suporte, cuidado e força que me deu durante toda minha vida e sobretudo no período acadêmico, lutando ao meu lado contra todas as adversidades. Por fazer de mim tudo o que eu sou hoje, por me ensinar a acreditar em mim mesmo e continuar seguindo um sonho, por mais distante e difícil que possa parecer.

Aos grandes amigos Asley Caldas, Paulo Girão, Jackson Peroba e Matheus Freire, que me proporcionaram valiosas conversas, momentos de distração e apoio incondicional, desde a minha infância, e todos aqueles que surgiram em meu caminho durante a minha trajetória. Ao compadre Walter Maia e o afilhado Tiago Maia, minha segunda família que amo. Aos colegas de curso que fizeram parte da graduação, destacando Halisson Andrade, Nilo Rocha, José Glauco, Igor Vieira, Gisleudo de Oliveira e Vitor Teodósio, que compartilharam comigo inúmeros momentos, tanto de felicidade quanto de dificuldade, onde muitas vezes foram apoio.

Ao Prof. Dr. Vitor Hugo Miro, pela excelente orientação, por todo o ensinamento durante as disciplinas, sempre buscando algo novo e útil para enriquecer o conhecimento de seus alunos. Pela paciência comigo na elaboração desse trabalho, tirando de mim a preocupação desse desafio.

Aos participantes da banca examinadora Prof. Dr. Francisco José Tabosa e Marcos Paulo pelo tempo, pelas valiosas colaborações e sugestões.

RESUMO

O cultivo da cana-de-açúcar é uma das principais atividades no Nordeste do Brasil, desempenhando importante função econômica para seus estados, além de gerar uma quantidade significativa de empregos para a região. Sua importância é ainda maior quando consideramos as inúmeras possibilidades em relação aos seus produtos e subprodutos gerados. Dessa forma, a tomada de decisão por parte dos envolvidos na cadeia produtiva é crucial para a manutenção dessa fonte de emprego e renda, principalmente no que diz respeito ao planejamento e, em específico, na análise do comportamento dos preços. Em vista disso, essa pesquisa explorou o uso da linguagem de programação Python e a aplicação de técnicas de séries temporais para a previsão de preços em um contexto específico, direcionado a cultura da cana-de-açúcar nos Estados de Alagoas, Pernambuco e Paraíba no período de 2014 a 2022. Ao longo deste estudo, identificamos que o modelo AR (1) seria uma maneira simples e eficiente para se obter os resultados esperados. No processo de modelagem, implementamos esse modelo e os resultados obtidos demonstram a viabilidade e a eficácia do uso de séries temporais e modelos autorregressivos para a previsão de preços no contexto estudado. No entanto, a pesquisa ainda não nos permite dizer que esse é o modelo mais adequado e preciso para a previsão, pois o ideal é que se tenha um comparativo de resultados obtidos com a aplicação de diferentes técnicas e circunstâncias.

Palavras-chave: Séries temporais; previsão de preços; cana-de-açúcar; estacionariedade.

ABSTRACT

The cultivation of sugarcane is a key activity in Northeast Brazil, serving as a significant economic source for its states and generating a considerable number of jobs in the region. Its importance extends further when considering the numerous possibilities regarding its derived products and by-products. Consequently, decision-making by stakeholders in the production chain becomes crucial for maintaining this source of employment and income, particularly with regard to prices. In light of this, the present research explored the use of the Python programming language and applied time series techniques for price forecasting in a specific context, focusing on sugarcane cultivation in the states of Alagoas, Pernambuco, and Paraíba from 2014 to 2022. Throughout this study, it was identified that the AR(1) model would be a simple yet efficient approach to achieve the expected results. In the modeling process, this model was implemented, and the results obtained demonstrate the feasibility and effectiveness of utilizing time series and autoregressive models for price forecasting in the studied context. However, further research is necessary to determine whether this model is the most suitable and accurate for prediction, as a comparative analysis of results specific to the circumstances of the study is ideal.

Keywords: Time series; price forecast; sugarcane; stationarity.

Lista de Figuras

Figura 1: Modelos de previsão.....	155
Figura 2: Ambiente do Google Colab.	20
Figura 3: Série e distribuição de preços em 1ª diferença, funções de autocorrelação e autocorrelação parcial (dados de treino).	28

Lista de Tabelas

Tabela 1: Dados iniciais e finais da série de preços.	20
Tabela 2: Coeficiente de correlação entre o preço e o preço defasado.	25
Tabela 3: Estatísticas descritivas da série de preços (dados de treino).....	27
Tabela 4: Resultados do teste de Dickey-Fuller (dados de treino).	27
Tabela 5: Sumário do modelo AR(1) (dados de treino).....	29

Lista de Gráficos

Gráfico 1: Séries de preços pagos ao produtor da Cana-de-açúcar nos estados do Nordeste (2014-2022).	233
Gráfico 2: Série de preços para os estados da Paraíba, Pernambuco e Alagoas (2014-2022).	24
Gráfico 3: Série de preços pagos ao produtor de Cana-de-açúcar correspondentes aos estados de AL, PE e PB, incluindo o preço médio (2014-2022).	24
Gráfico 4: Correlação serial entre o preço e o preço defasado.	25
Gráfico 5: Séries de preço pagos ao produtor da Cana-de-açúcar: dados de treino e dados de teste.	26
Gráfico 6: Série de preços observados e preços previstos (dados de treino).....	300
Gráfico 7: Série de preços observados e preços previstos (dados de teste - 2022).	300

SUMÁRIO

1	INTRODUÇÃO	11
2	REVISÃO DE LITERATURA	13
2.1	Séries Temporais	14
<i>2.1.1</i>	<i>Transformações e ajustes</i>	16
2.2	Estacionariedade	16
2.3	Técnica Box-Jenkins	17
2.4	Modelo Arima	17
3	METODOLOGIA	19
3.1	Compilação e visualização dos dados	19
3.2	Correlação serial	21
<i>3.2.1</i>	<i>Estacionariedade da série</i>	21
<i>3.2.2</i>	<i>Primeira diferença</i>	21
3.3	Modelo Autorregressivo de primeira ordem (AR1)	22
3.4	Validação de treino e teste	22
3.5	Erro quadrático médio (EQM) e erro absoluto médio (EAM)	22
4	RESULTADOS E DISCUSSÃO	23
5	CONCLUSÃO	32
	REFERÊNCIAS	33

1 INTRODUÇÃO

A cana-de-açúcar é uma cultura que possui importância mundial, e no Brasil não é diferente, sendo o primeiro produto de cultivo da história do país e consolidando seu espaço na economia, tornando o país o maior produtor (IEA, 2021). Esse destaque da cultura se dá principalmente pela sua versatilidade em relação aos subprodutos e suas diversas aplicações em outras indústrias. Inicialmente podemos dar ênfase ao etanol e ao açúcar como principais subprodutos, pois para o açúcar temos o Brasil como segundo maior produtor e maior exportador e para o etanol o país também tem protagonismo como o segundo maior produtor (VIDAL, 2022).

O açúcar é parte indispensável da alimentação humana e contribui até mesmo para a indústria farmacêutica na produção de xaropes. O etanol é usado principalmente como combustível, mas há também o uso em bebidas alcoólicas e na indústria química. Além disso, a cana-de-açúcar é consumida como bebida in natura, conhecida como caldo de cana e seu processamento permite a obtenção do melaço, açúcar mascavo e da rapadura. Ademais, temos o retorno dessa planta para uso agrícola por meio da vinhaça que é o resíduo da produção de álcool, tornando-se rico em macro e micronutrientes e aplicando-se como fertilizante orgânico ou incorporado à ração de animais. O bagaço também pode ser convertido em alimento animal, além de fabricação de papel e geração de energia. Este último uso, inclusive, se mostra como uma alternativa viável economicamente e com ótimo potencial energético (BORRERO, 2003).

Diante do exposto e levando em consideração o cenário agrícola atual, esse trabalho tem por motivação auxiliar o planejamento de diversos setores da cadeia produtiva, desde o pequeno agricultor que busca seu sustento e alguma forma de agregar valor ao seu negócio, quanto aos governos que precisam avaliar o mercado global a fim de entender a demanda e por consequência controlar melhor a sua exportação. Similarmente, Bressan (2001) aponta que as técnicas de previsão auxiliam no processo de tomada de decisões dos agentes participantes do mercado em atividades que requerem planejamento, análise de políticas e minimização da incerteza, assumindo importância expressiva no setor agropecuário, constantemente sujeito a distúrbios irregulares.

Em vista disso, as séries de preços se colocam como uma possibilidade clara para entender o comportamento econômico. O avanço tecnológico em diversas áreas nos permite testar possibilidades para esta temática, uma delas é buscar o auxílio da programação para

facilitar e automatizar processos, como a compilação e análise de dados de modo que se alcance o resultado esperado.

Partindo dessa explanação, as perguntas norteadoras nos levam aos seguintes problemas: como podemos prever os preços da cana de açúcar no Nordeste baseado em suas séries temporais? Que tipo de modelo é mais adequado para tal?

Portanto, esse trabalho objetiva aplicar os métodos de análises temporais e técnicas de estimação e previsão para estudar o comportamento do preço da cana-de-açúcar pago ao produtor nos estados do Nordeste do Brasil.

A pesquisa busca contribuir para os campos do agronegócio em relação a previsão de preços de commodities e análise de série temporais, especificamente para o nordeste brasileiro, fornecendo informações valiosas para produtores, empresas do setor sucroenergético e órgãos governamentais, contribuindo para a tomada de decisões estratégicas, a gestão de riscos e o desenvolvimento sustentável do mercado de cana de açúcar.

O trabalho está dividido em mais quatro seções, além desta introdução. Na próxima seção, são abordados os principais trabalhos e conceitos desta temática. Em seguida, na terceira seção, explicita-se a metodologia adotada, com a descrição da base de dados a ser aplicada no modelo proposto. Na quarta seção, apresentam-se os resultados e sua discussão. Por fim, são tecidas as considerações finais do estudo.

2 REVISÃO DE LITERATURA

Devido à importância da previsão de preços de commodities para ajudar produtores e investidores a tomar decisões, há muitos trabalhos relacionados a esse tema. A modelagem ARIMA e a técnica de Box e Jenkins (1976) são metodologias amplamente utilizadas para previsão de seres temporais nesses trabalhos.

No trabalho de Soares et al. (2012) buscou-se estimar modelos de previsão dos preços médios da castanha de caju recebidos pelos produtores no estado do Ceará e identificar o modelo que apresenta melhor previsão no período de julho de 1994 a setembro de 2009. Comparando os métodos Box e Jenkins e as redes neurais artificiais, os resultados mostraram que o melhor modelo de previsão de preços é o ARIMA (1, 1, 4) obtido pelo método Box e Jenkins (1976), pois em relação ao método de redes neurais a porcentagem de erro é menor.

Souza (2022) valida os componentes de tendência, sazonalidade e volatilidade dos preços da manga pagos aos produtores do Vale do Submédio São Francisco. Em seu trabalho, também foi realizado um estudo para prever o futuro preço da manga para as próximas 18 semanas em relação ao período do estudo. Os resultados mostram tendências positivas e sazonalidade nos períodos de 12 e 28 semanas. Os preços da manga Palmer estão sujeitos a flutuações condicionais, que têm sido mais voláteis desde 2016. Esta série usa o modelo SARIMA (1,1,0) x (0,0,1)⁵² para previsão de preços, exatamente pela influência da sazonalidade. O modelo se ajusta bem em termos de erro médio absoluto e erro médio percentual.

A pesquisa de Santos (2016) procurou avaliar se os produtores do estado de São Paulo seriam guiados em suas decisões de produção mais, predominantemente, pelos preços. Dentro deste contexto, o trabalho objetivou identificar se há influência dos preços do açúcar, do etanol e da própria cana-de-açúcar na área plantada de cana-de-açúcar no estado de São Paulo, no período de 1995 a 2015. Faz-se uso da metodologia proposta por Box-Jenkins de Função Transferência, que se constitui num método multivariado de séries temporais e que apresenta vantagens em relação aos métodos tradicionais de estimação. Os resultados demonstraram que os preços têm influenciado o aumento na área de cana-de-açúcar, em especial, o preço do açúcar.

Santos et al. (2012) avaliaram a eficácia dos modelos de séries temporais ARIMA (Autorregressivo Integrado de Médias Móveis) e SARIMA (Modelo Sazonal Autorregressivo Integrado de Médias Móveis) na previsão de preços do boi gordo em Campos dos

Goytacazes-RJ. Para isso, utilizaram a metodologia de *Box-Jenkins* para a modelagem da série de preços do boi gordo na localidade, sendo o poder de previsão dos modelos medido pelo indicador Erro Quadrado Médio de Previsão (EQMP). Com base no resultado concluiu-se que os modelos são instrumentos eficazes na previsão dos preços do boi, especialmente o modelo SARIMA que apresentou o menor erro.

Na pesquisa de Reichert e Souza (2020) foram utilizados os modelos Autorregressivos Integrados de Médias Móveis (ARIMA) para prognosticar o preço da celulose em atacado e exportada pelo Brasil. Observou-se que o preço da celulose em atacado e da celulose exportada sofrem oscilações em períodos semelhantes, devido à relação direta com a cotação do dólar e com as crises financeiras nos países importadores. O modelo de melhor acurácia para prognosticar o preço da celulose em atacado foi o modelo ARIMA (1,1,0) enquanto o modelo ARFIMAX (1, d^* ,0) obteve o melhor desempenho para prognosticar o preço da celulose exportada. Assim, as metodologias empregadas foram eficazes para prognosticar e analisar as inter-relações entre as variáveis.

2.1 Séries temporais

Para Morettin & Toloí (2006) uma série temporal é qualquer conjunto de observações ordenadas no tempo. Para Montgomery (2004), pode ser definida como uma área da estatística dedicada ao estudo de dados orientados no tempo. Portanto, ao analisar séries temporais, estaremos observando um conjunto de dados que foram compilados ao longo de um determinado período de tempo. Esse mecanismo é amplamente utilizado nas mais diversas áreas e, embora os dados mais comuns sejam em negócios e economia, podemos vê-los em áreas como, saúde, população, segurança pública, esportes e questões sociais. (DOANE e SEWARD, 2014).

Segundo Morettin & Toloí (1981), ao se trabalhar com essa metodologia, podemos estar interessados em:

- a) Investigar o mecanismo gerador da série temporal; por exemplo, analisando uma série de alturas de ondas, podemos querer saber como essas ondas foram geradas;
- b) Fazer previsões de valores futuros da série; estas podem ser a curto prazo, como para séries de vendas, produção e estoque, ou a longo prazo, como para séries populacionais, de produtividade, etc.;

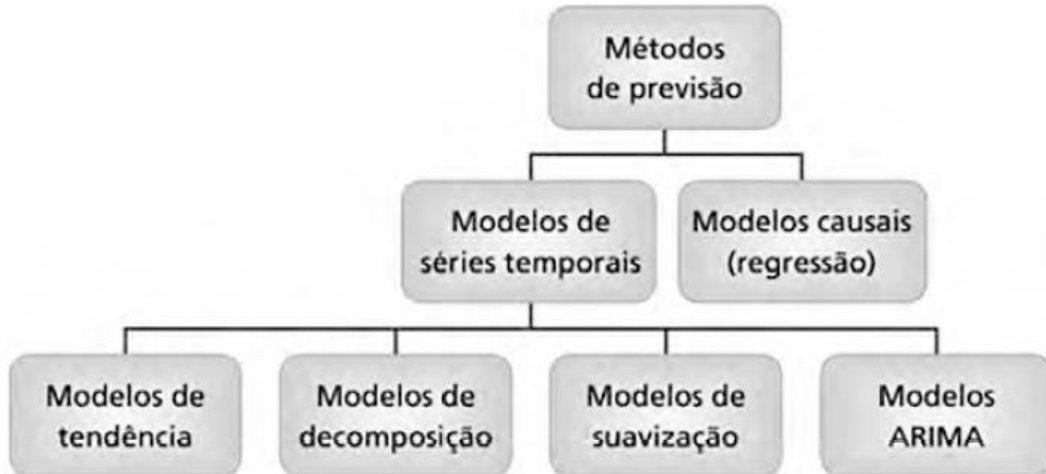
c) Descrever apenas o comportamento da série; nesse caso, a construção do gráfico, a verificação da existência de tendências, ciclos e variações sazonais, a construção de histogramas e diagramas de dispersão, etc., podem ser ferramentas úteis;

d) Procurar periodicidades relevantes nos dados; neste caso, com o auxílio de análise espectral.

Seja qual for a aplicação, os dados obtidos podem atuar como importantes ferramentas para governos, empresas, vendedores, produtores, entre outras atividades que sejam contempladas por esses interesses, objetivando fazer previsões que auxiliem na tomada de decisão.

Para se alcançar o objetivo, há diversos métodos de previsão, de acordo com a situação. A figura 1 mostra os principais modelos utilizados para previsões:

Figura 1: Modelos de previsão.



Fonte: Doanne e Seward (2014, p.615).

Em seu trabalho, Fava (2000) decompõe uma série temporal em quatro componentes, são eles:

a) Tendência (T): trata-se de movimento contínuo dos dados numa certa direção, refletindo o declínio, a elevação ou a estabilidade (não havendo tendência) do valor médio de uma série histórica no longo prazo;

b) Ciclo (C): refere-se a movimentos não regulares em torno do nível médio da tendência, com um período maior que um ano;

c) Sazonalidade (S): assim como componente ciclo, a sazonalidade apresenta movimento oscilatório em torno do nível médio da tendência. No entanto, ocorre em subperíodos de tempo fixo de um ano;

d) Volatilidade (I): ocorre devido a fatores estritamente aleatórios.

Um exemplo de tendência pode ser visto no valor do Produto Interno Bruto (PIB) ou nos preços das ações que tendem a crescer, decair ou permanecerem constantes. Já o componente ciclo pode ser encontrado na venda de bens de capital. A sazonalidade representa as vendas de produtos em uma época determinada ou estação do ano, por exemplo. Finalmente, a volatilidade (frequentemente chamada de irregularidade) decorre de causas sociais ou naturais, como epidemias ou guerras. Vale ressaltar que é possível que apenas um componente esteja presente na série, a combinação de alguns ou todos eles ao mesmo tempo.

2.1.1 Transformações e ajustes

Hyndman e Athanasopoulos (2021) acreditam que ajustes aos dados podem levar a uma série temporal mais simples. Logo, o objetivo desses ajustes é simplificar os dados históricos por meio da remoção de fontes conhecidas de variação ou tornando o padrão mais consistente em todo o conjunto de dados. Geralmente padrões mais simples levam a previsões mais precisas.

2.2 Estacionariedade

Souza et al. (2009) afirmam que ao se trabalhar com séries temporais é importante que as variáveis sejam estacionárias ou passíveis de sua estacionariedade. Essa característica é fundamental para previsão do futuro com base na regressão de séries temporais, solidificando a premissa de que o futuro se comportará de acordo com o passado. Os autores deixam claro ainda que a primeira tarefa realizada no trabalho é a verificação quanto à estacionariedade das variáveis utilizadas.

Uma série temporal é estacionária quando suas características estatísticas (média, variância, autocorrelação, ...) são constantes ao longo do tempo. É uma série que se

desenvolve aleatoriamente no tempo, em torno de uma média constante, refletindo alguma forma de equilíbrio estatístico estável. (MADDALA e LAHIRI, 2009)

2.3 Técnica Box-Jenkins

A obra “*Time series analysis: forecasting and control (1970)*” publicada por Box e Jenkins, foi precursora de uma nova geração de ferramentas de previsão. Popularmente conhecida como metodologia Box-Jenkins (BJ), mas tecnicamente como modelagem ARIMA. A ênfase desses métodos não está na construção dos modelos de equações únicas ou de equações simultâneas, mas na análise probabilística, ou estocástica, das propriedades da própria série temporal econômica. (GUJARATI, 2011)

Segundo Morettin e Tolo (2004) a metodologia de Box e Jenkins (1970) “consiste em ajustar modelos autorregressivos integrados a médias móveis – ARIMA (p, d, q) – a um conjunto de dados. Os autores mencionam ainda que a estratégia para construção deste modelo é baseada em um ciclo iterativo, no qual a escolha da estrutura do modelo baseia-se nos próprios dados (MORETTIN e TOLOI, 2004). De acordo com Werner e Ribeiro (2003), estes modelos matemáticos abordam o comportamento da autocorrelação entre os valores da série temporal e, a partir disso, possibilitam realizar previsões, principalmente para curto prazo.

Conforme Vasconcellos e Alves (2000), a relação temporal considerada pela metodologia de Box e Jenkins (1976) é representada por um conjunto de características estocásticas, definidas como modelo ARIMA, que incorpora termos autorregressivos (AR), filtro de integração e termos de Médias Móveis (MA).

2.4 Modelo ARIMA

De acordo com Ediger e Akar (2007), o ARIMA é um dos mais populares modelos para análise da previsão de demanda para series temporais. O modelo ARIMA é um caso especial do modelo ARMA. ARMA é um modelo autorregressivo de médias móveis, enquanto o ARIMA é um modelo autorregressivo integrado de médias móveis. Portanto, o modelo ARIMA se originou a partir de modelos de autorregressão e das médias móveis, sendo uma combinação dos dois. (GUJARATI, 2000)

Os modelos ARIMA são modelos que utilizam apenas dados históricos de series temporais com o intuito de expressar como as series reagem de acordo com a variação estocástica anterior (BABAI et al, 2013).

Uma das suposições mais comuns sobre uma série temporal é que ela é estacionária, ou seja, evolui aleatoriamente em torno de um valor médio constante, refletindo alguma forma de equilíbrio contínuo. No entanto, a maioria das séries que encontramos na prática possuem alguma forma de não estacionariedade. Sob o mesmo ponto de vista, Gujarati (2000) menciona que “muitas series temporais econômicas são não-estacionarias, ou seja, são integrais”. Logo, se para análise de uma série temporal for necessária a sua diferenciação “d” vezes para torná-la estacionária, diz-se que esta série temporal é ARIMA (Auto Regressiva Integrada de Média Móvel). Assim, será representada por ARIMA(p,d,q), onde p indica o número de termos autorregressivos, d o número de vezes que a série deve ser diferenciada para se tornar estacionária e, q indica o número de termos de média móvel (GUJARATI, 2000).

3 METODOLOGIA

O presente trabalho realizou uma pesquisa descritiva, iniciando com consulta à base de dados do Google Acadêmico, Scielo e Periódicos Capes. As palavras chave utilizados foram: cana-de-açúcar, séries temporais e previsão de preços. Dessa forma, por meio da técnica de revisão bibliográfica, foram escolhidos trabalhos semelhantes a esta linha de pensamento a fim de avaliar seus métodos e resultados. As buscas ocorreram entre agosto e setembro de 2022 e o critério de inclusão levou em consideração a relevância, profundidade e atualidade dos estudos.

Posteriormente foram coletados dados de séries de preço da cultura da cana-de-açúcar para os estados do Nordeste do Brasil no site da Companhia Nacional de Abastecimento (CONAB), foram compiladas 108 observações, representadas em reais por tonelada, com frequência mensal, iniciando no mês de janeiro de 2014 até dezembro de 2022. Esses dados foram tratados via excel e compilados no Google Colaboratory, que utiliza a linguagem de programação python e submetidos aos testes estatísticos para alcançar o objetivo proposto. Vale destacar que foi utilizada uma abordagem quantitativa na análise dos dados e resultados.

3.1 Compilação e visualização dos dados

A parte prática se deu início no ambiente do Google Colaboratory com a importação das principais bibliotecas da plataforma e a adição dos dados tratados previamente. A visualização foi feita inicialmente em forma de tabelas e gráficos, que serão mostrados a seguir:

Figura 2: Ambiente do Google Colab.

```

TCC_IGOR_analise_preco_cana.ipynb
Arquivo Editar Ver Inserir Ambiente de execução Ferramentas Ajuda Todas as alterações foram salvas
RAM Disco
+ Código + Texto
[1] # Importar bibliotecas
import numpy as np
import pandas as pd
import matplotlib.pyplot as plt
import seaborn as sns

# Envio do arquivo
from google.colab import files
arquivo = files.upload()

Escolher arquivos dados_preco_cana.csv
• dados_preco_cana.csv(text/csv) - 5901 bytes, last modified: 13/03/2023 - 100% done
Saving dados_preco_cana.csv to dados_preco_cana.csv

[3] # Importar dados
df = pd.read_csv('dados_preco_cana.csv', sep=';')

[4] # Visualizar informações dos dados
df.info()

<class 'pandas.core.frame.DataFrame'>
RangeIndex: 108 entries, 0 to 107
Data columns (total 10 columns):
# Column Name Non-Null Count Dtype
  
```

Fonte: Elaborado pelo autor.

Tabela 1: Dados iniciais e finais da série de preços.

	AL	BA	CE	MA	PB	PE	PI	RN	SE	DATA
2014-01	59.33	NaN	57.36	55.00	62.54	62.54	85.00	62.18	65.00	2014-01-31
2014-02	58.77	NaN	58.10	55.00	62.63	62.63	85.00	63.12	62.81	2014-02-28
2014-03	58.77	NaN	59.70	55.00	65.22	64.22	85.00	64.22	63.50	2014-03-31
2014-04	58.93	66.39	60.00	55.00	68.20	68.20	85.00	67.21	68.01	2014-04-30
2014-05	59.86	72.00	60.60	55.00	69.03	68.86	85.00	68.86	68.22	2014-05-31
...
2022-08	NaN	181.00	188.38	160.42	183.77	183.44	168.39	186.89	NaN	2022-08-31
2022-09	NaN	182.00	193.50	158.76	168.30	165.67	163.10	187.35	NaN	2022-09-30
2022-10	141.65	185.00	194.26	158.76	158.32	155.38	155.26	168.58	151.17	2022-10-31
2022-11	141.71	NaN	194.26	156.67	154.64	157.30	161.54	160.37	150.70	2022-11-30
2022-12	141.71	NaN	194.86	156.67	161.49	165.89	164.73	162.18	151.05	2022-12-31

108 rows × 10 columns

Fonte: Resultados da pesquisa.

Após visualizar os dados, notamos que os estados da Bahia, Maranhão e Sergipe possuem muitos dados faltantes (representados pela sigla NaN, ou not a number) em suas respectivas séries, dessa forma tomamos a decisão de não trabalhar com eles para não

mascarar o resultado. Em adição, as séries de Piauí e Ceará possuem uma flutuação muito alta e incomum entre 2015 e 2019, sendo totalmente discrepantes em relação aos demais, logo, vamos trabalhar apenas com os seguintes: Alagoas, Paraíba e Pernambuco, que não só possuem as maiores produções da região Nordeste como também uma maior área destinada a elas. Os dados faltantes dos estados escolhidos foram preenchidos com interpolação linear.

3.2 Correlação serial

Em seguida, verificamos a correlação serial, visando comprovar se os valores observados em um determinado período da série são influenciados por valores de períodos anteriores ou futuros. Essa verificação também busca identificar a presença de padrões de dependência citados anteriormente, tais como ciclo, tenência e sazonalidade.

3.2.1 Estacionariedade da série

Para caracterizar se a série é de fato estacionária é preciso realizar um teste de estacionariedade. O resultado do teste mostra uma análise estatística pelo teste de Dickey-Fuller que apresenta gráficos de autocorrelação e autocorrelação parcial. No caso de haver componentes de tendência e sazonalidade ou outro padrão anormal, tem-se que retirar ou modelar esses componentes.

3.2.2 Primeira diferença

A decomposição é uma etapa que pode ser realizada previamente para visualização individual dos componentes. Realizamos a decomposição aditiva e multiplicativa da nossa série e comprovamos a presença de sazonalidade, que pode ser retirada com a diferenciação.

Uma vez que a série não é estacionária, aplica-se uma diferenciação de primeira ordem com o objetivo de remover fontes de variação e tornar a série estacionária. Ao aplicar essa função, conseguimos tornar a série mais propícia a modelagem e previsão. Após essa etapa, as estatísticas de autocorrelação e autocorrelação parcial fazem um maior sentido e a interpretação nos permite decidir qual método será utilizado para estimar o modelo.

3.3 Modelo Autorregressivo de primeira ordem (AR1)

Após os testes foi decidido pela utilização de um modelo autorregressivo de primeira ordem (AR1). Nesse modelo, o valor atual da série é determinado pela soma de uma constante e um múltiplo do valor anterior, juntamente com o erro aleatório. O modelo pode ser representado matematicamente de forma simples pela equação 1:

$$Y_t = \phi Y_{t-1} + u_t \quad (1)$$

Nessa representação, Y_t é o valor atual da série, o símbolo “phi” é o coeficiente que indica a relação entre os valores atual e anterior, Y_{t-1} é o valor anterior no tempo $t-1$ e u_t é o ruído ou erro aleatório.

3.4 Validação de treino e teste

Para a estimação do modelo e previsão vamos adotar a estratégia de dividir os dados da amostra em um conjunto de dados de treino e um conjunto de dados de teste. Adotando este procedimento, vamos estimar o nosso modelo empregando os dados de treino e, com o modelo estimado, vamos realizar previsões que terão sua acurácia verificada nos dados de teste. Na presente aplicação vamos separar os 12 últimos meses como dados de teste. Essa metodologia busca comprovar a eficácia do modelo. Em caso de eficácia comprovada, o modelo está apto para ser utilizado com valores posteriores não conhecidos.

3.5 Erro quadrático médio (EQM) e erro absoluto médio (EAM)

Para avaliar o desempenho de um modelo, são utilizadas algumas medidas, como o erro quadrático médio e o erro absoluto médio. O EQM é uma métrica que avalia os erros com um peso maior, pois é calculado somando o quadrado das diferenças do valor previsto e do valor real, dividido pelo número de observações. Logo, diferenças grandes entre a previsão e a observação levarão a um valor de erro maior. (RABELO, 2019)


Já o EAM é útil para avaliar a média das previsões sem levar em consideração a direção do erro (positivo ou negativo), somando as diferenças absolutas entre os valores previstos e os reais e dividido pelo número de observações.

Os respectivos resultados de cada etapa serão apresentados no capítulo seguinte.

4 RESULTADOS E DISCUSSÕES

O gráfico 1 a seguir apresenta o registro completo das séries de preços pagos ao produtor de cana-de-açúcar no Nordeste.


Gráfico 1: Séries de preços pagos ao produtor da Cana-de-açúcar nos estados do Nordeste (2014-2022).



Fonte: Resultados da pesquisa.


Como citado anteriormente, a presença de dados faltantes em meses do conjunto, pode inviabilizar a previsão ou enviesar o resultado. Alagoas, Pernambuco e Paraíba possuíam menos dados faltantes e flutuações semelhantes, além de serem os maiores produtores da região, logo, optamos por trabalhar com uma média desses 3 estados, conforme gráficos 2 e 3 a seguir.

Gráfico 2: Série de preços para os estados da Paraíba, Pernambuco e Alagoas (2014-2022).



Fonte: Resultados da pesquisa

Gráfico 3: Série de preços pagos ao produtor de Cana-de-açúcar correspondentes aos estados de AL, PE e PB, incluindo o preço médio (2014-2022).




Fonte: Resultados da pesquisa

A nova série que será alvo do estudo foi chamada de “preco_m”. Com ela, podemos dar início a análise, que começou com os logaritmos do preço que é o valor de todas as entradas da série e do preço defasado, valor anterior de cada entrada, buscando comprovar

a correlação entre os valores. O valor preço e o logaritmo do mesmo, passou por diferenciação e o resultado pode ser conferido em um gráfico de dispersão a seguir.

Gráfico 4: Correlação serial entre o preço e o preço defasado.



Fonte: Resultados da pesquisa.

Na tabela 2, temos ainda o coeficiente de correlação, onde o preço é representado por “preço_m” e o preço defasado é representado por “lag_preço”.

Tabela 2: Coeficiente de correlação entre o preço e o preço defasado.


	preço_m	lag_preco
preço_m	1.000000	0.994231
lag_preco	0.994231	1.000000

Fonte: Resultados da pesquisa.

Analisando o gráfico e os valores dos coeficientes, podemos perceber que existe uma alta correlação entre o preço de um período e o valor anterior a esse período. Isso nos mostra que a série é previsível, entretanto, ainda não nos garante que haverão bons resultados nessas previsões. Em adição, um modelo autorregressivo de primeira ordem, parece ser o mais adequado para estimar a série nesse momento, visto que o valor de um período anterior já mostrou a correlação elevada.

Após a divisão de treino e teste, foi plotado um gráfico com essa representação.

Gráfico 5: Séries de preço pagos ao produtor da Cana-de-açúcar: dados de treino e dados de teste.



Fonte: Resultados da pesquisa.

Com base no gráfico 5, podemos perceber que existe uma quantidade significativa de dados para treino, para que o modelo consiga captar os padrões da série e executar uma previsão mais precisa.

A Tabela 3 apresenta estatísticas descritiva da série de preços.

Tabela 3: Estatísticas descritivas da série de preços (dados de treino).

	Dados em nível	Dados em 1ª diferença
Nº de observações	96.000000	95.000000
Média	91.058299	1.116667
Desvio-padrão	25.238355	2.910214
Valor mínimo	61.230000	-6.693333
Percentil 25	77.270000	0.910000
Percentil 50 (Mediana)	87.133333	0.603333
Percentil 75	97.033333	2.560000
Valor máximo	167.553333	9.350000

Fonte: Resultados da pesquisa.

Na Tabela 4 são apresentados os resultados do teste de Dickey-Fuller para as séries em nível e em primeira diferença. Verifica-se que os dados em nível não são estacionários, mas ao tomar a primeira diferença da série temos uma série estacionária.

Tabela 4: Resultados do teste de Dickey-Fuller (dados de treino).

	Dados em nível	Dados em 1ª diferença
Valor do teste	0.9106	-3.0968
Valor-p	0.9932	0.0268
Lags usados	3.0000	2.0000
Nº de observações usado	92.0000	92.0000
Valor Crítico de referência (1%)	-3.5035	
Valor Crítico de referência (5%)	-2.8935	
Valor Crítico de referência (10%)	-2.5838	

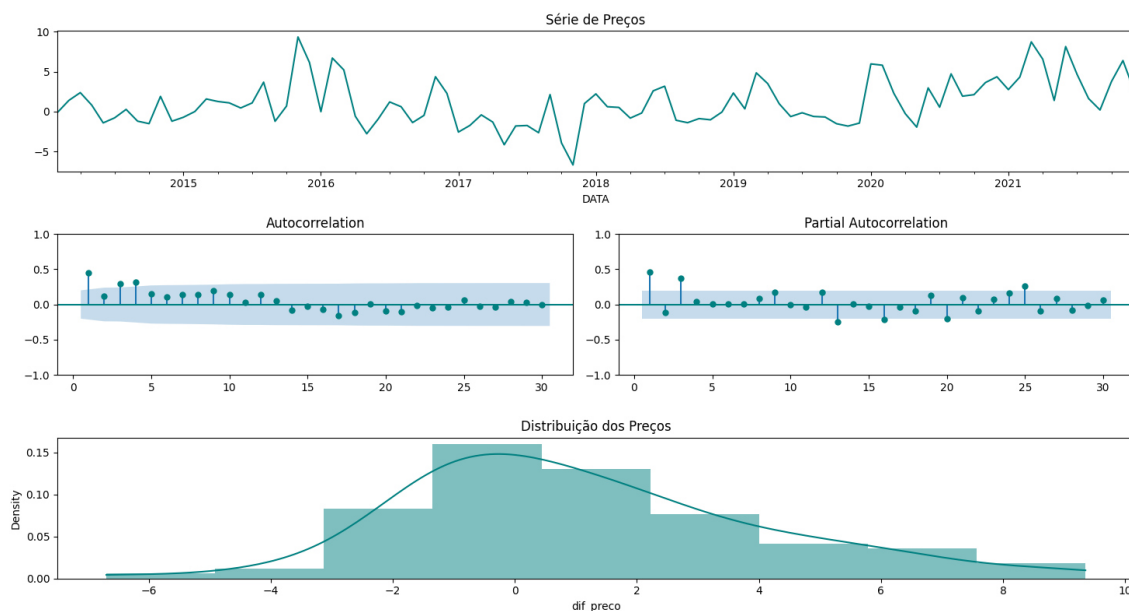
Fonte: Resultados da pesquisa.

Como apresentado, os dados em nível, são inferiores em módulo aos valores críticos de referência para 1%, 5% e 10%. Isso nos mostra que não podemos rejeitar a

hipótese nula de que a série não é estacionária. Já os dados em primeira diferença são superiores em módulo aos valores críticos de referência para 5%, rejeitando a hipótese nula, reforçado pelo p-valor menor que 0,05. Ou seja, a série se tornou estacionária em primeira diferença.

Na Figura 3 temos a variação dos preços da série, os gráficos das funções de autocorrelação e autocorrelação parcial, e a distribuição da série de preços em primeira diferença.

Figura 3: Série e distribuição de preços em 1ª diferença, funções de autocorrelação e autocorrelação parcial (dados de treino).



Fonte: Resultados da pesquisa.

Analisando o gráfico da imagem, temos uma série livre de tendências. Obtendo uma série estacionária, a análise dos gráficos das funções de autocorrelação e autocorrelação parcial permite inferir a respeito de diferentes possibilidades de modelagem. A autocorrelação evidencia que não temos componentes de médias móveis, que seria representado por um decaimento constante nos lags. Na autocorrelação parcial podemos notar os lags 1 e 3 fora do intervalo de confiança (destacado pela sombra azul do gráfico), na presente aplicação vamos optar por uma opção parcimoniosa e aplicar uma estrutura de um modelo autorregressivo de ordem 1, visto que o primeiro lag parece mais relevante para se definir a ordem de atraso.

A Tabela 5 apresenta um resumo do modelo AR(1) e seus coeficientes e estimativas.

Tabela 5: Sumário do modelo AR(1) (dados de treino).

	coeficiente	erro-padr	z	P> z 	[0,025	0,975]
Intercepto	1,1172	0,541	2,064	0,039	0,056	2,178
ar.L1	0,4529	0,099	4,592	0,000	0,260	0,646
sigma	6,6325	0,0886	7,486	0,000	4,896	8,369
N. de obs	96					
Log Likelihood	-224,784					
AIC	455,568					
BIC	463,261					

Fonte: Resultados da pesquisa.

Adotando um nível de nível de significância de 5%, tem-se que o intercepto e o coeficiente autorregressivo são estatisticamente significantes. Interpretando os valores, temos que o intercepto é de 1,1172 quando todas as outras variáveis estiverem no valor zero. O coeficiente ar.L1 refere-se ao primeiro lag da variável de resposta, com valor de 0,4529 indica uma autocorrelação positiva. A estimativa de sigma representa a variância do erro aleatório, quanto maior o seu valor, maior será a variabilidade dos resíduos e por consequência, menor a precisão do modelo em prever a série. Considerando este resultado temos uma equação estimada dada por:

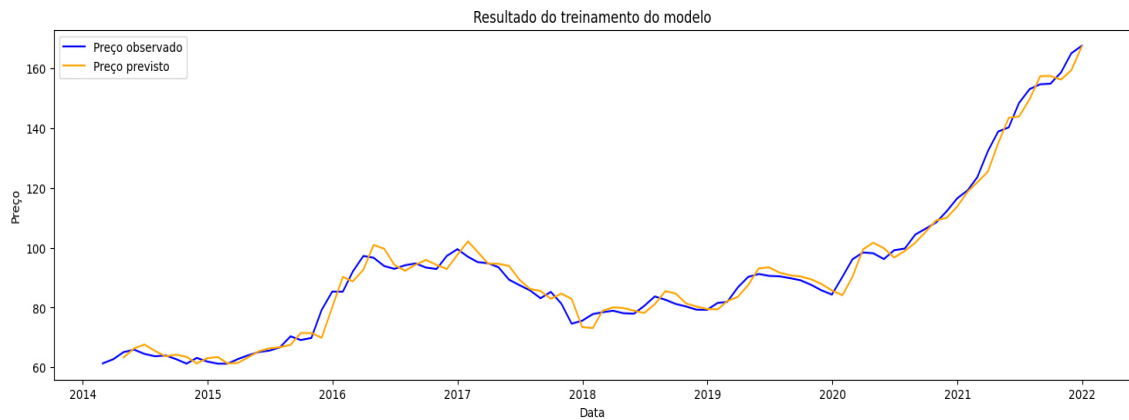
$$\Delta p_t = 1,1172 + 0,4529 \Delta p_{t-1} + e_t ; e_t \sim N(0; 6,6325) \quad (2)$$

Na presente análise foram realizadas previsões “mês a mês”. Assim, com base nesse modelo podemos fazer estimações de preços para cada período (mês) t da seguinte forma:

$$\hat{p}_t = \hat{p}_{t-1} + \Delta \hat{p}_t \quad (3)$$

O gráfico 6 mostra as séries de preços observados e preços previstos aplicando o modelo estimado e os dados de treino.

Gráfico 6: Série de preços observados e preços previstos (dados de treino).

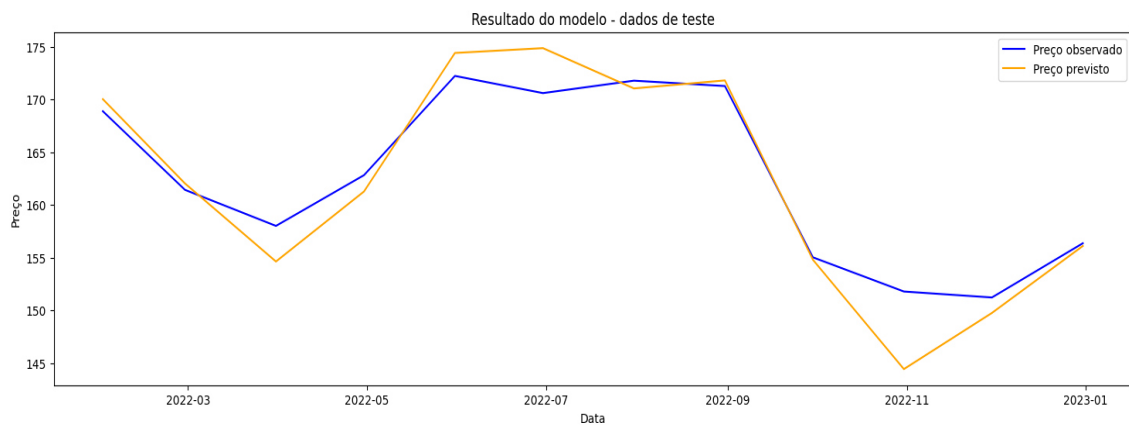


Fonte: Resultados da pesquisa.

Com base no gráfico, podemos afirmar que os preços previstos seguem de perto os preços observados, apontando para um modelo que capta bem o comportamento da série temporal. Após calcular as medidas de erro para o conjunto de treino, temos uma medida de erro quadrático médio de 2,9656 e de erro absoluto médio de 1,2800.

A partir do modelo estimado, a verdadeira performance preditiva do modelo deve ser avaliada no conjunto de dados de teste. Conforme indicado anteriormente, os valores observados em 2022 foram destacados da base como dados de teste. O gráfico 7 apresenta a série de preços médios observados em 2022 e a série prevista com o emprego do modelo estimado.

Gráfico 7: Série de preços observados e preços previstos (dados de teste - 2022).



Fonte: Resultados da pesquisa.

Assim como nas previsões geradas no conjunto de dados de treino, deve-se avaliar o ajuste das previsões ao conjunto de dados de teste; que são as previsões que realmente importam para a análise. Para os dados de teste, os valores de preços previstos mais uma vez acompanharam a tendência dos preços observados, mesmo que com maior distância. Em situações em que se compara diferentes modelos, estas estatísticas permitem avaliar qual deles apresenta o melhor resultado em termos de acurácia das previsões. Para as previsões geradas sobre a série definida como teste, foi calculada uma medida de erro quadrático médio de 9,4111 e de erro absoluto médio de 2,1969.

5 CONCLUSÃO

Este estudo demonstrou que o uso de técnicas de séries temporais, como o modelo AR(1), pode ser uma abordagem promissora para a previsão de preços e atendeu o objetivo proposto de aplicar técnicas de estimação e previsões para analisar séries temporais da cana-de-açúcar produzida na região Nordeste.

Na análise da série temporal contendo o preço médio da cana-de-açúcar entre o ano de 2014 e 2022 nos estados de Alagoas, Pernambuco e Paraíba, o modelo escolhido se ajustou bem em termos de erro quadrático médio e erro absoluto médio, obtendo EQM de 9,4111 e EAM de 2,1969 no conjunto de teste.

O trabalho contribui para o campo da previsão de preços, fornecendo uma base sólida para pesquisas futuras. Recomenda-se a continuação da pesquisa, explorando abordagens mais avançadas, considerando e comparando diferentes modelos preditivos.

Tais técnicas podem ser de grande valia para as atividades de planejamento dos agentes que atuam no mercado de cana-de-açúcar na região, como produtores e beneficiadores. Analisar as séries temporais de preços permite uma compreensão melhor do comportamento dos preços e a mitigação de riscos.

REFERÊNCIAS

- BABAI, M. Z. et al. Forecasting and inventory performance in a two-stage supply chain with ARIMA(0,1,1) demand: Theory and empirical analysis. **International Journal Of Production Economics**, [s.l.], v. 143, n. 2, p.463-471, jun. 2013. Elsevier
BV.<http://dx.doi.org/10.1016/j.ijpe.2011.09.004>
- BORRERO, M. A. V. *et al.* An environmental management method for sugar cane alcohol production in Brazil. **Biomass and Energy**, [S. l.], v. 25, n. 3, 5 abr. 2003. Research Article, p. 287-299. DOI 10.1016/S0961-9534(03)00032-1. Disponível em:
<https://www.sciencedirect.com/science/article/pii/S0961953403000321>. Acesso em: 30 set. 2022.
- BOX, G. E. P.; JENKINS, G. M. **Time series analysis, forecasting and control**. San Francisco: Holden-Day, 1976.
- BRESSAN, A. A. **Modelos de previsão de preços aplicados aos contratos futuros agropecuários**. 2001. 152 f. Tese (Doutorado em Economia Aplicada) - Universidade Federal de Viçosa, Viçosa, 2001.
- CONAB - COMPANHIA NACIONAL DE ABASTCIMENTO. Acompanhamento da safra brasileira de cana-de-açúcar, Brasília, DF, v. 9, n. 2, agosto 2022.
- DOANE, David P.; SEWARD, Lori E. **Estatística aplicada à administração e economia**. 4. ed. Porto Alegre: AMGH Editora Ltda, 2014. 826 p. ISBN 978-85-8055-394-9. Disponível em: <https://app.minhabiblioteca.com.br/books/9788580553949>. Acesso em: 12 ago. 2022.
- EDIGER, V. Ş.; AKAR, S. ARIMA forecasting of primary energy demand by fuel in Turkey. **Energy Policy**, [s.l.], v. 35, n. 3, p.1701-1708, mar. 2007. Elsevier BV.
<http://dx.doi.org/10.1016/j.enpol.2006.05.009>.
- FAVA, V. L. (2000). Título Capítulo 8. In M. A. S. Vasconcelos & D. Alves (Eds.), **Manual de econometria**. São Paulo: Editora Atlas.
- GUJARATI, D. N. **Econometria básica**. 3 ed. São Paulo: Pearson Makron Books, 2000. 846 p.
- GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria Básica**. 5. ed. Brasil: Bookman, 2011. 918 p. ISBN 9788563308320. Disponível em:
https://www.academia.edu/40156994/ECONOMETRIA_B%C3%81SICA_5_edi%C3%A7%C3%A3o_Gujarati. Acesso em: 8 set. 2022.
- HYNDMAN, RJ, & ATHANASOPOULOS, G. (2021) **Previsão: princípios e prática**, 3ª edição, OTextos: Melbourne, Austrália. OTexts.com/fpp3. Acesso em 14 set. 2022.
- MADDALA, G.S.; LAHIRI, Kajal. **Introductions to Econometrics**. 2. ed. Chichester: Wiley, 2009. 656p. ISBN 978-0-470-01512-4.

MONTGOMERY, D. C. **Introdução ao Controle Estatístico da Qualidade**. [S.l.]: LTC, 2004. ISBN 8521614004.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. São Paulo: Edgard Blücher, 2004. 535 P.

MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: Edgard Blücher, 2006.

MORETTIN, Pedro Alberto; TOLOI, Clélia Maria de Castro. **Modelo para Previsão de Séries Temporais**. Rio de Janeiro: Instituto de Matemática Pura e Aplicada, 1981. 372 p. Disponível em: <https://pt.scribd.com/doc/249877164/Morettin-e-Toloi-Analise-de-Series-Temporais#>. Acesso em: 17 set. 2022.

NACHILUK, K. Alta na Produção e Exportações de Açúcar Marcam a Safra 2020/21 de Cana. **Análises e Indicadores do Agronegócio**, São Paulo, v. 16, n. 6, jun. 2021, p. 1-5. Disponível em: <http://www.iea.sp.gov.br/out/TerTexto.php?codTexto=15925>. Acesso em: 05 nov. 2022.

RABELO, Leandro. Princípios básicos para criar previsões de Séries Temporais. *In: Ensina.AI*. 15 maio 2019. Disponível em: <https://medium.com/ensina-ai/princ%C3%ADpios-b%C3%AAsicos-para-criar-previs%C3%B5es-de-s%C3%A9ries-temporais-e58c451a25b>. Acesso em: 7 mar. 2023.

REICHERT, B.; SOUZA, A. M. Previsão e interação dos preços da celulose brasileira nos mercados interno e externo. **Ciência Florestal**, [S. l.], v. 30, n. 2, p. 501–515, 2020. DOI: 10.5902/1980509838223. Disponível em: <https://periodicos.ufsm.br/cienciaflorestal/article/view/38223>. Acesso em: 01 set. 2022.

SANTOS, Vladimir Faria dos *et al.* Previsão de preços do boi gordo com modelos ARIMA e SARIMA. **Revista Eletrônica de Economia da Universidade Estadual de Goiás – UEG**, Goiás, v. 8, n. 2, p. 27-44, Julho/Dez 2012. Disponível em: <https://www.revista.ueg.br/index.php/economia/article/view/440>. Acesso em: 1 set. 2022.

SANTOS, Jaqueline Zani dos. **Influência dos preços do açúcar e etanol na variação da área de cana-de-açúcar no estado de São Paulo**. Orientador: Maura Seiko Tsutsui Esperancini. 2016. 92 p. Tese (Doutorado em Agronomia) - Universidade Estadual Paulista, Botucatu, 2016.

SOARES, Naisy Silva et al. Análise de Previsões de Preços da Castanha de Caju no Ceará. **Revista Econômica do Nordeste**, [s. l.], v. 43, n. 03, p. 487-500, Julho - Setembro 2012. Disponível em: <https://www.bnb.gov.br/revista/index.php/ren/article/view/237/215>. Acesso em: 1 set. 2022.

SOUZA, Ana Cledia Ferreira de; LIMA, João Ricardo Ferreira de. Comportamento dos preços de manga Palmer ao produtor do Vale do Submédio São Francisco. **Revista de Economia e Sociologia Rural**, [s. l.], v. 61, n. 01, 14 mar. 2022. DOI <https://doi.org/10.1590/1806-9479.2021.250161>. Disponível em:

<https://www.scielo.br/j/resr/a/wbQ6pwLWXgFJwTjHccsyx5b/?lang=pt>. Acesso em: 1 set. 2022.

SOUZA, V. S.; HENRIQUE, B.; ALMEIDA, A. N.; EISFELD, C. L.. **Análise de séries temporais de preços de compensado no estado do Paraná, com a utilização da metodologia de Box & Jenkins.** In: Sci. For., Piracicaba, v. 37, n. 81, p. 061-069, mar. 2009, 2009. Disponível em:
https://www.academia.edu/10916304/Análise_do_preço_externo_do_compensado_paranaens_e_atraves_da_metodologia_de_Box_and_Jenkins_Paranas_plywood_external_price_analysis_using_the_Box_and_Jenkins_methodology. Acesso em: 07 set. 2022.

VASCONCELLOS, M. A. S.; ALVES, D. **Manual de econometria.** São Paulo: Atlas, 2000

VIDAL, Maria de Fátima. Agropecuária: Açúcar. Fortaleza: BNB, ano 7, n.256, nov. 2022. (Caderno Setorial Etene)

VIDAL, Maria de Fátima. Indústria: Etanol. Fortaleza: BNB, ano 7, n.260, dez. 2022. (Caderno Setorial Etene)

WERNER, L., & RIBEIRO, J. L. D. (2003). **Previsão de demanda: uma aplicação dos modelos Box- Jenkins na área de assistência técnica de computadores pessoais.** Gestão & Produção, 10(1), 47-67.