

UNIVERSIDADE FEDERAL DE SANTA MARIA
CENTRO DE CIÊNCIAS NATURAIS E EXATAS
CURSO DE ESPECIALIZAÇÃO EM ESTATÍSTICA E MODELAGEM
QUANTITATIVA

Maiara de Oliveira Noronha

**AJUSTAMENTO DE UM MODELO DE PREVISÃO POR MEIO DA
TÉCNICA AUTORREGRESSIVA DE MÉDIAS MÓVEIS E ENTRADA
EXÓGENA PARA A PRODUÇÃO BRASILEIRA DE BIODIESEL**

Santa Maria, RS
2018

Maiara de Oliveira Noronha

**AJUSTAMENTO DE UM MODELO DE PREVISÃO POR MEIO DA
TÉCNICA AUTORREGRESSIVA DE MÉDIAS MÓVEIS E ENTRADA
EXÓGENA PARA A PRODUÇÃO BRASILEIRA DE BIODIESEL**

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Especialista em Estatística e Modelagem Quantitativa**.

Orientador: Prof. Dr. Adriano Mendonça Souza

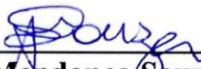
Santa Maria, RS
2018

Maiara de Oliveira Noronha

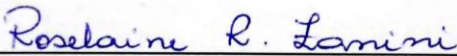
**AJUSTAMENTO DE UM MODELO DE PREVISÃO POR MEIO DA TÉCNICA
AUTORREGRESSIVA DE MÉDIAS MÓVEIS E ENTRADA EXÓGENA PARA A
PRODUÇÃO BRASILEIRA DE BIODIESEL**

Monografia apresentada ao curso de Especialização em Estatística e Modelagem Quantitativa, da Universidade Federal de Santa Maria (UFSM, RS) como requisito parcial para obtenção do título de **Especialista em Estatística e Modelagem Quantitativa**.

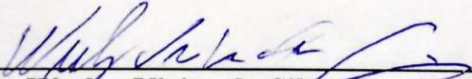
Aprovado em 10/08/2018



Adriano Mendonça Souza, Dr. (UFSM)
(Presidente/Orientador)



Roselaine Ruviano Zanini, Dr. (UFSM)



Wesley Vieira da Silva, Dr. (UFSM)

Santa Maria, RS
2018

RESUMO

AJUSTAMENTO DE UM MODELO DE PREVISÃO POR MEIO DA TÉCNICA AUTOREGRESSIVA DE MÉDIAS MÓVEIS E ENTRADA EXÓGENA PARA A PRODUÇÃO BRASILEIRA DE BIODIESEL

AUTORA: Maiara de Oliveira Noronha
ORIENTADOR: Adriano Mendonça Souza

O objetivo desta pesquisa foi analisar a produção brasileira de biodiesel considerando a influência de variáveis macroeconômicas, assim como ajustar um modelo de previsão por meio da modelagem ARMAX. Foi realizada uma análise descritiva das variáveis, bem como a análise de causalidade por meio do teste de Granger. Por fim foi realizada a previsão da produção brasileira de biodiesel por meio d modelagem ARMAX. Foi observada a existência de relações diretas entre a Produção de Biodiesel com o Preço do Óleo de Soja, o Preço da Soja em Grão, a Produção de Petróleo, a Produção de Gás Natural e o PIB. O modelo ajustado que melhor descreve a produção de biodiesel foi um SARIMAX $(0,1,2)(1,0,0)_{12} \Delta(\text{Preço do Óleo de Soja})_{t-3} \Delta(\text{Produção de Petróleo})_{t-5} \Delta(\text{PIB})_{t-2} \Delta(\text{Produção de Gás Natural})_{t-2;t-5}$. Tal modelo foi capaz de capturar adequadamente o comportamento da variável analisada, a partir da influência de variáveis externas, pois os valores originais de julho a dezembro de 2017, encontram-se dentro do intervalo de confiança. Além disso, os valores das estatísticas de acurácia do modelo, MAE (22424,74), MAPE (5,6992%) e U-Theil (0,026921) foram adequados. Dessa forma, os resultados da presente pesquisa contribuem com a área de estudo sobre o biodiesel, pois por meio da modelagem foi possível obter uma previsão acurada da produção brasileira de biodiesel, e nesse sentido a implementação de técnicas avançadas para prever, tanto a produção quanto o consumo de biodiesel ou outras variáveis que possam influenciar o comportamento de biocombustíveis, podem ser consideradas alternativas eficazes e fonte de informação para tomada de decisão no que diz respeito ao planejamento do setor de biocombustíveis.

Palavras-chave: Biodiesel. Previsão de Séries Temporais. Modelos ARMAX.

ABSTRACT

ADJUSTMENT OF A FORECAST MODEL BY THE AUTOREGRESSIVE MOVING AVERAGE MODEL WITH EXOGENOUS INPUTS FOR THE BRAZILIAN BIODIESEL PRODUCTION

AUTHOR: Maiara de Oliveira Noronha

ADVISOR: Adriano Mendonça Souza

The objective of this research was to analyze the Brazilian biodiesel production considering the influence of macroeconomic variables, as well as adjusting a forecast model through ARMAX modeling. A descriptive analysis of the variables was performed, as well as the causality analysis using the Granger test. Finally, the Brazilian biodiesel production was estimated by ARMAX modeling. It was observed the existence of direct relations between Biodiesel Production with Soybean Oil Price, Soybean Price, Oil Production, Natural Gas Production and GDP. The adjusted model that best describes the production of biodiesel was a SARIMAX (0,1,2) (1,0,0) 12 Δ (Price of Soybean Oil) t-3 Δ (Production of Oil) t-5 Δ (GDP) t-2 Δ (Natural Gas Production) t-2; t-5. This model was able to adequately capture the behavior of the analyzed variable, from the influence of external variables, since the original values from July to December 2017 are within the confidence interval. In addition, the values of the model accuracy statistics, MAE (22424,74), MAPE (5,6992%) and U-Theil (0,026921) were adequate. Thus, the results of the present research contribute to the study area on biodiesel, because through the modeling it was possible to obtain an accurate forecast of the Brazilian biodiesel production, and in this sense the implementation of advanced techniques to predict both production and the consumption of biodiesel or other variables that may influence the behavior of biofuels can be considered as effective alternatives and source of information for decision making regarding the planning of the biofuels sector.

Keywords: Biodiesel. Forecast of Time Series. ARMAX Models

SUMÁRIO

1	INTRODUÇÃO	6
1.1	JUSTIFICATIVA	6
1.2	OBJETIVOS	7
1.2.1	Objetivo geral	7
1.2.2	Objetivos específicos	7
1.3	ESTRUTURA DO TRABALHO	8
2	REVISÃO DE LITERATURA	9
2.1	ASPECTOS ECONÔMICOS E SOCIOAMBIENTAIS DA PRODUÇÃO DE BIODIESEL	9
2.2	MODELOS DE SÉRIES TEMPORAIS	12
2.2.1	Modelos Estacionários	14
2.2.2	Modelos Não-Estacionários	16
2.2.3	Modelos Sazonais	17
2.2.4	Modelos Autorregressivos de Médias Móveis e Entradas Exógenas	17
2.2.5	Etapas da Metodologia de Box-Jenkins	18
3	MATERIAIS E MÉTODOS	22
3.1	DESCRIÇÃO DAS VARIÁVEIS	22
3.2	PROCEDIMENTOS METODOLÓGICOS	23
4	RESULTADOS E DISCUSSÃO	25
5	CONCLUSÃO	39
	REFERÊNCIAS	40

1 INTRODUÇÃO

O abastecimento energético foi um dos fatores determinantes para o desenvolvimento das sociedades modernas, principalmente após a revolução industrial e da criação de tecnologias que proporcionaram o avanço das fronteiras comerciais. O setor de transportes, desde o final do século 18, passou por um constante crescimento em consequência da criação de carros movidos a combustíveis fósseis, o que também contribuiu para o aumento da demanda energética global. O setor de transportes é o segundo maior consumidor de energia, ficando apenas atrás do setor industrial, no qual estima-se que, cerca de 60% do consumo mundial de petróleo, provém desse setor (ATABANI et al., 2012).

Devido ao aumento da demanda por energia e a depreciação dos combustíveis fósseis, faz-se necessária a busca por novas fontes de combustíveis. Nesse caso, os biocombustíveis podem ser considerados uma alternativa viável econômica e socioambientalmente. Conforme informações da Agência Internacional de Energia (AIE), a demanda de energia mundial, em 2030, terá um acréscimo equivalente à metade do que é consumido nos dias atuais, sendo que os países China e Índia serão os maiores consumidores (AIE, 2017).

Nesse contexto, o biodiesel torna-se interessante por vários motivos: é altamente biodegradável e tem toxicidade mínima, pode substituir diesel combustível em muitas aplicações diferentes, como em caldeiras e motores de combustão sem grandes modificações e sem diminuir o desempenho desses equipamentos, quase zero emissões de sulfatos, compostos aromáticos e outras substâncias químicas que são nocivas ao meio ambiente, uma pequena contribuição líquida de dióxido de carbono (CO₂), considerando todo o seu ciclo de vida (cultivo, produção de óleo e conversão para biodiesel), além de causar uma melhoria significativa do potencial econômico rural (AHMAD et al., 2011).

Portanto, nesta pesquisa se propõe a análise e ajuste de um modelo de previsão da produção brasileira de biodiesel considerando a influência de variáveis macroeconômicas, a partir da aplicação de um modelo Autorregressivo de Médias Móveis e Entradas Exógenas – ARMAX.

1.1 JUSTIFICATIVA

O Brasil está entre os principais produtores mundiais de biodiesel, fato que torna as fontes de energias renováveis importantes na composição da matriz energética brasileira. Em 2016, o país atingiu uma produção de 3,8 milhões de m³, no entanto esse volume foi 3,5%

inferior em comparação ao ano de 2015. Com exceção da Região Sul, cuja produção aumentou 2,9% no período, foram registradas quedas nas regiões Nordeste, Sudeste, Norte e Centro-Oeste de 3,2%, 13,9%, 41,2% e 5,8%, respectivamente. A Região Centro-Oeste permaneceu como a maior produtora de biodiesel, com volume de cerca de 1,6 milhão de m³, equivalente a 43,3% da produção nacional. Em seguida a Região Sul, com uma produção de 1,5 milhão de m³, 41% do total nacional (ANP, 2017).

Alguns dos principais marcos regulatórios para o setor de biocombustíveis líquidos, no Brasil, são o Programa Nacional do Álcool (Proálcool, Decreto n° 76.593/75), a Lei da Inovação (Lei 10.973/04), a Lei do Biodiesel (Lei 11.097/05), o Plano Nacional de Agroenergia (PNA 2006–2011) e o Plano de Aceleração do Crescimento (PAC 2007–2010) (ESTEVEZ; PEREIRA, 2016). Dessa maneira, faz-se importante que gestores e governantes possibilitem a formulação e incorporação de políticas públicas de fomento ao desenvolvimento regional e inclusão social sobre bases tecnológicas, econômicas, sociais e ambientais equilibradas (SANTOS et al., 2017).

Dessa forma, é relevante considerar nos estudos empíricos e análises técnicas, todos os aspectos socioeconômicos e ambientais da geração de energia pelas diferentes fontes que compõem a matriz energética brasileira. No caso desta pesquisa, o estudo da produção de biodiesel que é uma realidade em vários países, como Estados Unidos da América, Malásia, Indonésia, Brasil, Alemanha, França, Itália e outros países europeus, considerada uma fonte importante para o progresso econômico e social.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Esta pesquisa tem como objetivo geral determinar a influência das variáveis macroeconômicas na produção brasileira de biodiesel, e ajustar um modelo de previsão mensal para a mesma série por meio da modelagem ARMAX.

1.2.2 Objetivos específicos

Verificar a influência das variáveis macroeconômicas para explicar a variância da produção de biodiesel.

Realizar a previsão *in sample* para a validação do modelo ajustado como um bom previsor do comportamento da produção brasileira de biodiesel.

1.3 ESTRUTURA DO TRABALHO

A presente pesquisa está dividida em cinco capítulos, apresentados a seguir:

O **capítulo 1** aborda a introdução do tema, a justificativa da pesquisa, apresenta o objetivo geral do trabalho, assim como os específicos, e a estrutura do trabalho.

O **capítulo 2** apresenta uma revisão de literatura sobre a produção de biodiesel e os modelos de séries temporais.

O **capítulo 3** apresenta os materiais e métodos, são descritas as variáveis consideradas no estudo, e os procedimentos metodológicos adotados.

O **capítulo 4** apresenta os resultados, assim como a discussão desses em relação a outros estudos presentes na literatura abordada.

O **capítulo 5** apresenta a conclusão.

2 REVISÃO DE LITERATURA

Neste capítulo é apresentada uma revisão de literatura sobre a produção de biodiesel e os modelos de séries temporais.

2.1 ASPECTOS ECONÔMICOS E SOCIOAMBIENTAIS DA PRODUÇÃO DE BODIESEL

A constituição das civilizações sempre esteve atrelada à busca por fontes de energia. A biomassa foi uma das principais fontes de energia, e ainda extensivamente utilizada até o último quarto do século 19. No entanto, foi aos poucos sendo substituída pelo carvão mineral e, no início do século 20, pelo petróleo. Assim, com o crescimento da população, ocorreu o desenvolvimento econômico, industrial e tecnológico, exigindo maior intensidade na exploração do uso de petróleo e seus derivados para atender as demandas dos diversos setores da sociedade, com destaque para o setor de transportes o qual é um dos principais consumidores de combustíveis líquidos, especialmente, a gasolina e o diesel (ATABANI et al., 2012; CARDOSO; SHIKIDA; FINCO, 2017a).

O abastecimento energético foi um dos fatores determinantes para o desenvolvimento das sociedades modernas, principalmente após a revolução industrial e a criação de tecnologias que proporcionaram o avanço das fronteiras comerciais. O setor de transportes, desde o final do século 18, passou por um constante crescimento em consequência da criação de carros movidos a combustíveis fósseis, o que também contribuiu para o aumento da demanda energética global. O setor de transportes é o segundo maior consumidor de energia, ficando apenas atrás do setor industrial, e estima-se que cerca de 60% do consumo mundial de petróleo provém desse setor (ATABANI et al., 2012).

A produção de biocombustíveis utilizando como fonte os óleos vegetais começou a ser desenvolvida no final do século 19 quando Rudolf Diesel, em 1895, começou a desenvolver seus experimentos e constatou que poderia utilizar esse tipo de matéria-prima como combustível. Em uma apresentação em Paris, Diesel, demonstrou o primeiro motor de ignição por compressão movido a biocombustível (KNOTHE; VAN GERPEN; KRAHL, 2010).

No entanto, o contexto da época não favoreceu a continuidade das pesquisas sobre o uso dos óleos vegetais para produção de combustível, pois ainda havia grande disponibilidade de petróleo, uma crescente demanda impulsionada pelo avanço da indústria e o aumento da demanda por automóveis. Dessa maneira, os derivados do petróleo ganharam maior destaque

no mundo todo, por serem mais rentáveis que os óleos vegetais (HO; NGO; GUO, 2014; GUPTA; VERMA, 2015).

A viabilidade do uso de óleos vegetais em motores veiculares voltou a ser discutida na década de 1970, em consequência das crises de petróleo e do crescente debate em torno das questões ambientais. Por essas razões, governos e especialistas, retomaram as discussões acerca do uso de fontes renováveis de energia, tanto como substitutos dos combustíveis fósseis quanto por serem fontes menos poluentes. Nesse sentido, as fontes de energia renováveis voltaram a ser objeto de novas pesquisas e estudos técnicos, incluindo o uso de óleos vegetais como combustível em motores veiculares (CARDOSO; SHIKIDA; FINCO, 2017b; BERGMANN et al., 2013).

No Brasil, desde a década de 1970, ocorre o estímulo ao desenvolvimento de novas fontes energéticas a partir do uso mais intenso da biomassa, destacando-se especialmente a produção de etanol. Enquanto o programa do biodiesel, foi incorporado efetivamente no debate da matriz energética somente na última década do século 20 (FURLANETTO; SANTOS, 2014). Pela lei 11.097, de 13.01.2005, o biodiesel constitui-se em uma fonte renovável de energia derivada de produtos agrícolas, biomassa florestal e outras matérias orgânicas, além de produtos de origem animal, que pode ser utilizado em motores de combustão, substituindo parcial ou totalmente os combustíveis de origem fóssil (BERGMANN et al., 2013).

Dessa forma, o biodiesel pode ser considerado uma alternativa viável por ser altamente biodegradável e com toxicidade mínima, pode substituir o diesel combustível em muitas aplicações diferentes, como em caldeiras e motores de combustão sem grandes modificações e sem diminuir o desempenho desses equipamentos. Além disso, apresenta quase zero emissões de sulfatos, compostos aromáticos e outras substâncias químicas que são nocivas ao meio ambiente, uma pequena contribuição líquida de dióxido de carbono (CO₂), considerando todo o seu ciclo de vida (cultivo, produção de óleo e conversão para biodiesel), além de causar uma melhoria significativa do potencial econômico rural (ARANSIOLA et al., 2014).

Globalmente, são identificadas mais de 350 culturas como fontes potenciais para a produção de biodiesel. A vasta gama de matérias-primas disponíveis para a produção de biodiesel representa um dos fatores mais significativos para a produção. Porém, a matéria-prima deve cumprir dois requisitos principais, baixos custos de produção e grande escala de produção, e ainda a disponibilidade dessa matéria-prima depende do clima regional, da localização geográfica, das condições locais do solo e práticas agrícolas de cada país (BERGMANN et al., 2013).

Em termos de marco regulatório, o governo federal definiu como prioridade a ampliação da produção e consumo em escala comercial e de forma sustentável, com enfoque na inclusão social e no desenvolvimento regional, por meio da diversificação das matérias-primas e das regiões produtoras, visando gerar emprego e renda (SOUZA et al., 2015).

O setor brasileiro de biodiesel está em uma posição favorável e pioneira devido às informações técnicas disponíveis e à incorporação de estratégias em nível nacional. No entanto os processos estratégicos de negócios, para esse setor, devem estar alicerçados na governança das interações e articulações entre os vários atores setoriais afim de garantir o cumprimento das finalidades dos programas de desenvolvimento sustentável (RICO; SAUER, 2015; CÉSAR et al., 2017; MORENO-PÉREZ; MARCOSSI; ORTIZ-MIRANDA, 2017).

Nesse sentido, diante das discussões sobre mudanças climáticas globais, emissão de gases de efeito estufa, instabilidade de preços de petróleo e transição para mudanças na matriz energética mundial, as inovações tecnológicas tem papel importante para estimular a criação de soluções exequíveis no setor energético, pois os processos de inovação ocorrem por meio do progresso no uso de conhecimentos, que ao longo do tempo possibilita melhores resultados e consequentemente ganhos de competitividade (KLEWITZ; HANSEN, 2014; LINGELBACH et al., 2015; ADAMS et al., 2016).

A produção brasileira de biodiesel é caracterizada por um padrão tecnológico consolidado, incluindo a produção de matéria-prima até os equipamentos e técnicas utilizados nas usinas de produção do biocombustível. No entanto, tais circunstâncias reduzem as possibilidades para a formação de um ambiente sistêmico, no qual seja possível instituir mudanças e inovar ao longo dos elos que formam a cadeia de produção. Nesse caso há a minimização, por exemplo, da importância em promover a diversificação das matérias-primas e distribuição regional da referida produção (AZEVEDO, 2013).

Desde a instituição do Programa Nacional de Uso e Produção de Biodiesel (PNPB) e da implantação de todos os seus instrumentos pesquisadores contribuem para as discussões acerca de questões como o incremento na produção e dos percentuais de mistura ao diesel, e dos avanços dessa política pública na promoção do desenvolvimento regional e da inclusão social (GALVÃO et al., 2016; SALGADO et al., 2016; FREITAS et al., 2017).

Pode-se, no caso brasileiro, considerar que a obtenção de energia a partir de produtos agrícolas é um processo de inovação que permite a abertura de novos mercados e novos consumos. Porém, há uma crescente necessidade de viabilizar a inserção de novos conceitos de inovação técnico-científica para o setor de biocombustíveis com o intuito de tornar o ambiente negocial e os processos produtivos além de sustentáveis mais competitivos e estimuladores do

desenvolvimento social e econômico (MELO; JANNUZZI; BAJAY, 2016; SILVA; MARCHI NETO; SEIFERT, 2016; AQUILA et al., 2017; BRADSHAW, 2017).

Na seguinte seção é apresentada uma revisão de literatura sobre os modelos de séries temporais e seus conceitos.

2.2 MODELOS DE SÉRIES TEMPORAIS

Conforme Souza (2016), uma série temporal pode ser definida como uma sequência de observações sobre uma variável em diferentes instantes de tempo, em que os dados são observados em pontos temporais discretos e equidistantes. A análise de séries temporais consiste em dois objetivos básicos: (i) identificar as características e propriedades da série e/ou (ii) realizar previsões. As séries temporais são compostas por quatro elementos:

- a) Tendência: verifica o sentido de deslocamento da série temporal ao longo do tempo;
- b) Ciclo: movimento ondulatório da série temporal, que ao longo de vários anos tende a ser periódico;
- c) Sazonalidade: movimento ondulatório de curta duração, normalmente inferior a um ano, em geral está associado a mudanças climáticas;
- d) Ruído aleatório ou erro: compreende a variabilidade intrínseca à série temporal, não podendo ser modelado.

Os erros oriundos do modelo ajustado são definidos pela diferença entre os valores reais da série temporal modelada e os valores previstos. De acordo com Bueno (2008), para um modelo adequado, a sequência de ruídos gerados deve ser não autocorrelacionada, possuir média zero e variância constante, sendo que, os ruídos quando atendem esses requisitos são denominados de ruído branco, cuja representação é $RB \sim (0, \sigma^2)$.

Parte-se, então, do pressuposto que exista um “mecanismo gerador” para os dados estudados, dessa forma, procura-se construir um modelo que represente razoavelmente bem tal mecanismo. A abordagem clássica parte da ideia de que uma série estudada Z é passível de ser decomposta por meio das seguintes generalizações (SOUZA, 2016):

$$Z_t = T + S + C + \varepsilon_t \quad (1)$$

Onde: T representa a tendência; S a sazonalidade; C o ciclo; ε_t o erro. Desta forma, uma série temporal pode ser estudada como uma combinação de seus componentes, além da estrutura aditiva a série pode ser multiplicativa, dada pelo produto de seus componentes.

De acordo com Montgomery, Jennings e Kulahci (2007), o processo de realização de previsões é composto de diversas etapas estruturadas, a primeira etapa consiste em definir qual o objetivo para a realização da previsão, assim como definir a forma que essa previsão será utilizada, comumente a definição do problema advém da necessidade de prever demandas, controlar um determinado processo, mensurar riscos, oferecer subsídios a tomada de decisão, dentre outros. A etapa seguinte, coleta de dados, consiste na obtenção dos dados históricos que serão utilizados para prever o comportamento futuro da variável estudada. Nessa etapa é importante definir quais dados serão relevantes ao estudo (WERNER, 2005).

Após a coleta dos dados, se faz necessário analisá-los a fim de definir qual técnica de previsão será empregada, na literatura existem diversas abordagens, técnicas e modelos previsores para séries temporais, variando de acordo a capacidade de acurácia, o objetivo, o horizonte de previsão e os custos envolvidos. Portanto, a obtenção de uma previsão acurada depende da utilização de uma técnica de previsão adequada aos dados estudados, sendo que a seleção entre os modelos ou técnicas de previsão dependerá principalmente da acurácia da previsão (MAKRIDAKIS; STEVEN; HYNDMAN, 1998).

Para previsões de séries temporais, alguns modelos estão consolidados na literatura. Dentre os mais utilizados se destaca a modelagem ARIMA desenvolvida por Box e Jenkins (1970), proposta inicialmente na publicação "*Time Series Analysis: Forecasting and Control*". Essa abordagem metodológica passou a ser conhecida como metodologia de Box-Jenkins ou modelagem ARIMA, que permite que a variável resposta analisada (Z_t) seja explicada pelos seus próprios valores passados, assim como em termos de seu erro estocástico (GUJARATI; PORTER, 2011).

O método de modelagem ARIMA é utilizado com os objetivos de analisar o comportamento de séries temporais e para realizar previsões para séries de médio comprimento, pois possibilita a verificação da existência de correlação entre os valores da série ao longo do tempo (MORETTIN, 2008). Os modelos de Box-Jenkins resultam da combinação de três filtros: o componente Autorregressivo (AR), o filtro de Integração (I) e o componente de Médias Móveis (MA). Uma série temporal pode ser modelada pela combinação dos três filtros, ou somente por um ou dois deles, resultando em diversos modelos com características diferentes (WERNER, 2005).

2.2.1 Modelos Estacionários

Um pressuposto básico para utilização da metodologia de Box-Jenkins é da estacionariedade da série temporal estudada, garantindo a significância dos parâmetros estimados ao longo dos períodos. Dessa forma, modelos estacionários assumem que o processo gerador da série é “equilibrado”, com sua média e variância constante ao longo do tempo (MONTGOMERY; JENNINGS; KULAHCI, 2007).

Um modelo denominado autorregressivo, de uma série temporal Z_t , é aquele descrito por seus valores passados do período “t”, adicionados de um erro ε_t no mesmo instante (GUJARATI; PORTER, 2011). Dessa forma, o modelo é denominado autorregressivo de ordem “p”, denotado $AR(p)$, sendo representado pela equação (2):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \phi_2 \tilde{Z}_{t-2} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t \quad (2)$$

Onde: ϕ_p é o parâmetro autorregressivo de ordem “p”; ε_t representa o erro ou ruído aleatório $RB \sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ):

$$\tilde{Z}_t = Z_t - \mu \quad (3)$$

O modelo é considerado estacionário para todo $|\phi| < 1$. Esta condição é denominada de condição de estacionariedade, estabelecendo que todas as raízes devem estar fora do círculo unitário para um processo de ordem finita. A identificação do modelo autorregressivo é feita por meio das funções de autocorrelação e autocorrelação parcial, que indicam a ordem do modelo a ser ajustado (BUENO, 2008).

A função de autocorrelação em um processo autorregressivo decai exponencialmente, podendo alternar de sinal. Para a função de autocorrelação parcial o decaimento ocorre de forma abrupta em um *lag* significativo “p”, indicando a ordem do modelo a ser ajustado (MORETTIN, 2011).

Um modelo denominado de médias móveis (*moving average*), de uma série temporal Z_t , é descrito em termos de seus erros ε_t do período atual, juntamente com os erros de períodos defasados “t” (GUJARATI; PORTER, 2011). Dessa forma, o modelo é chamado de médias móveis de ordem “q”, denotado $MA(q)$, dado pela equação (4):

$$\tilde{Z}_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (4)$$

Onde: θ_q é o parâmetro de médias móveis de ordem “ q ”; ε_t representa o erro ou ruído aleatório RB $\sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ).

Para o modelo de médias móveis o parâmetro estimado deve assumir $|\theta| < 1$. Tal restrição é denominada de condição de inversibilidade, dessa foram as raízes da equação devem cair fora do círculo unitário em um processo de ordem finita. A identificação do modelo é realizada por meio funções de autocorrelação e autocorrelação parcial, que indicam a ordem do modelo a ser ajustado (BUENO, 2008).

A função de autocorrelação de um modelo de médias móveis decai abruptamente no *lag* significativo, indicando a ordem “ q ” do modelo a ser ajustado. Para a função de autocorrelação parcial o decaimento ocorre de forma exponencial, podendo ocorrer em forma de uma senoide amortecida (MORETTIN, 2011).

Em um modelo denominado de autorregressivo de médias móveis, ocorrerá a combinação dos filtros AR e MA, pois em determinados casos as séries temporais não se ajustam a modelos puramente AR ou MA (GUJARATI; PORTER, 2011). Assim como nos modelos puros, o modelo ARMA se ajustará somente quando a série Z_t apresentar estacionariedade. Dessa forma, o modelo é denominado de autorregressivo de médias móveis de parâmetros “ p ” e “ q ”, denotado ARMA(p, q), expresso pela equação (5):

$$\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (5)$$

Onde: ϕ_p é o parâmetro autorregressivo de ordem “ p ”; θ_q é o parâmetro de médias móveis de ordem “ q ”; ε_t representa o erro ou ruído aleatório RB $\sim (0, \sigma^2)$; \tilde{Z}_t corresponde ao valor Z_t subtraído a média do processo (μ).

O modelo ARMA assume a mesma condição de estacionariedade de um modelo AR, isto é, $|\phi| < 1$, assim como a condição de invertibilidade de um modelo MA, isto é, $|\theta| < 1$. Assim como nos modelos puros, a identificação do modelo ARMA é realizada por meio das funções de autocorrelação e autocorrelação parcial, com ambas apresentando decaimento exponencial e/ou senoidal, o que torna a identificação dos parâmetros relativamente mais difícil (MONTGOMERY; JENNINGS; KULAHCI, 2007; BUENO, 2008).

2.2.2 Modelos Não-Estacionários

Em aplicações reais, raramente as séries temporais são estacionárias, isto é, com a média e a variância não constantes dependentes do tempo. A não estacionariedade de uma série temporal pode estar relacionada: (i) a existência de tendência nos dados estudados, com ausência de oscilação em torno de uma média constante e/ou (ii) a variabilidade dos dados não se mantem constante ao longo do tempo, indicando que a variância dos dados está se alterando (WERNER, 2005).

A verificação da estacionariedade se dá a priori por análise gráfica, sendo confirmada pela aplicação de testes de raízes unitárias. Os testes Augmented Dick-Fuller – ADF (DICKEY, 1984) e Kwiatkowski, Phillips, Schmidt e Shin – KPSS (KWIATKOWSKI et al., 1992) comumente são utilizados a fim de verificar a estacionariedade em séries temporais, sendo sugerido a utilização conjunta de ambos para obter resultados mais acurados sobre o grau de estacionariedade dos dados (SOUZA, 2016). Maiores detalhes sobre teste de estacionariedade em séries temporais podem ser vistos em Morettin (2011) e Bueno (2008).

Dessa forma, caso a série possua tendência, não sendo estacionária, se faz necessária a aplicação de diferenças entre os valores a fim de torná-la estacionária (GUJARATI; PORTER, 2011). A forma mais comum de realizar transformações em séries temporais, consiste em realizar diferenças entre os valores da série sucessivamente até a mesma se tornar estacionária, a primeira diferença é dada pela equação (6):

$$\Delta Z_t = Z_t - Z_{t-1} \quad (6)$$

A segunda diferença é dada pela equação (7):

$$\Delta^2 Z_t = \Delta(Z_t - Z_{t-1}) = Z_t - 2Z_{t-1} + Z_{t-2} \quad (7)$$

Comumente é suficiente a aplicação de uma ou duas diferenças para que a série se torne estacionária. Dessa forma, o número de “*d*” diferenças realizadas é denominada de ordem de integração, portanto o modelo é denominado de autorregressivo integrado de médias móveis de parâmetros “*p*”, “*d*” e “*q*” denotado ARIMA(*p,d,q*), dado pela equação (8):

$$w_t = \phi_1 w_{t-1} + \dots + \phi_p w_{t-p} + \theta_1 \varepsilon_{t-1} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t \quad (8)$$

Onde: $w_t = \Delta^d Z_t$; ϕ_p é o parâmetro autorregressivo de ordem “ p ”; θ_q é o parâmetro de médias móveis de ordem “ q ”; ε_t representa o erro ou ruído aleatório RB $\sim (0, \sigma^2)$

2.2.3 Modelos Sazonais

Além dos filtros autorregressivos e de médias móveis, a investigação da autocorrelação pode indicar correlação entre os períodos da série analisada, apontando presença de sazonalidade, nesse caso os modelos com componentes sazonais são chamados de SARIMA (*Seasonal Autoregressive Integrated Moving Average*). Os modelos denominados SARIMA são compostos da parte não sazonal, com parâmetros iguais aos modelos ARIMA (p, d, q) e de uma parte com os parâmetros sazonais (P, D, Q) $_s$, em que o “ s ” indica a ordem da sazonalidade. Dessa forma, a descrição genérica do modelo é denotada SARIMA (p, d, q) (P, D, Q) $_s$, dada pela equação 9 (SOUZA et al., 2011):

$$\phi(B)\Phi(B)\Delta^d\Delta^{ds}Z_t = \theta(B)\Theta(B)\varepsilon_t \quad (9)$$

Onde: ϕ e θ representam os parâmetros autorregressivos e de médias móveis; Φ e Θ representam os parâmetros sazonais autorregressivos e sazonais de médias móveis, B representa o operador retroativo, Δ^d a ordem de integração dada por d diferenças, Δ^{ds} a diferença sazonal; ε_t representa o erro ou ruído aleatório RB $\sim (0, \sigma^2)$.

A parte sazonal do modelo pode ser detectada a partir das funções de autocorrelação e autocorrelação parcial, em que a função decaí de forma senoidal. Uma sazonalidade de ordem 12 apresentará uma autocorrelação significativa nas defasagens “12, 24, 36 ...” (WERNER; RIBEIRO, 2003).

2.2.4 Modelos Autorregressivos de Médias Móveis e Entradas Exógenas

Box, Jenkins e Reinsel (2008) definem os modelos ARMAX como um modelo autorregressivo de médias móveis com dependência de uma ou mais séries exógenas, representadas no modelo pela letra “X”. As variações do modelo dependem da combinação dos componentes AR e MA, resultando nos modelos possíveis: autorregressivo com variáveis exógenas – ARX ou autorregressivo de médias móveis com variáveis exógenas – ARMAX.

A definição das variáveis exógenas pode ser obtida a partir da aplicação do teste de causalidade de Granger (1986), que permite verificar a relação de causa e efeito entre duas ou

mais variáveis defasadas, verificando a procedência temporal entre as séries. A hipótese nula do teste afirma que uma dada variável X não causa no sentido Granger variações na variável Y analisada, dessa forma ao rejeitar a hipótese nula do teste ($p\text{-valor} < \alpha$) a variável X é considerada candidata para explicar variações futuras da variável Y estudada (GUJARATI; PORTER, 2011).

Segundo Franses (1991), o modelo ARMAX tem vantagem, pois possibilita o estudo de mais de uma variável simultaneamente. Dessa forma o modelo permite a análise de variáveis exógenas defasadas correlacionadas a variável Z_t e, o modelo ARMAX genérico é representado matematicamente a seguir:

$$Z_t = \sum_{i=1}^p \phi_i Z_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t + \sum_{k=1}^{N_x} \beta_k Z_{t-k} \quad (10)$$

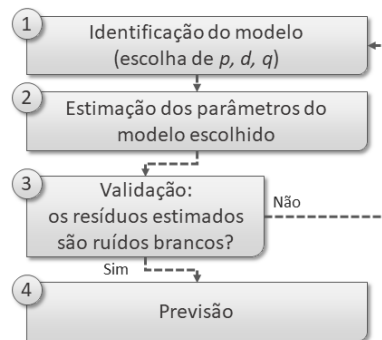
Em que: Z_t representa a variável modelada; ϕ_1, \dots, ϕ_p são coeficientes dos termos autorregressivos; Z_{t-1}, \dots, Z_{t-i} são os termos autorregressivos; ε_t é a componente aleatória, com características de RB $\sim (0, \sigma^2)$; $\theta_1, \dots, \theta_q$ são coeficientes dos termos das médias móveis; $\varepsilon_{t-1}, \dots, \varepsilon_{t-q}$ representam os termos das médias móveis; β_1, \dots, β_k são os coeficientes dos termos das variáveis exógenas.

Portanto, o modelo pretende explicar o comportamento de uma variável em função de variáveis exógenas defasadas. Nesse sentido, a aplicação do modelo ARMAX se justifica pela capacidade de identificar a relação de interação entre as variáveis, ainda sendo possível verificar até quando valores passados influem no comportamento da série (MAHMOUD, 1984; WERON, 2014; SENNA, 2015).

2.2.5 Etapas da Metodologia de Box-Jenkins

A modelagem de Box-Jenkins se constitui de um ciclo iterativo, permitindo ao fim determinar o melhor modelo predictor com base nas características de autocorrelação da série estudada (BOX; JENKINS, 1976). A Figura 1 ilustra a metodologia.

Figura 1 – Etapas da Metodologia de Box-Jenkins



Fonte: Adaptado de Gujarati e Porter (2011).

Inicialmente é verificada a estacionariedade da série e realizadas as devidas transformações, se necessário. Nesta etapa também é determinado o modelo para representar a série por meio da análise da função de autocorrelação (ACF) e função de autocorrelação parcial (PACF), resumidos no Quadro 1.

Quadro 1 – padrões teóricos da ACF e PACF para seleção de filtros

Tipo de Modelo	Padrão Teórico da ACF	Padrão Teórico da PACF
AR(p)	A função de autocorrelação com decaimento exponencial e/ou senoidal	A função de autocorrelação parcial decai de forma abrupta no <i>lag</i> significativo “ p ”
MA(q)	A função de autocorrelação decai de forma abrupta no <i>lag</i> significativo “ q ”	A função de autocorrelação parcial com decaimento exponencial e/ou senoidal
ARMA(p, q)	Declínio exponencial e/ou senoidal	Declínio exponencial e/ou senoidal

Fonte: Elaborado a partir de Souza (2016), Gujarati e Porter (2011), Morettin (2011).

Após selecionados os filtros para compor o modelo, parte-se para a estimação dos parâmetros “ p ” e “ q ”. A estimação dos parâmetros é realizada por meio do método dos mínimos quadrados ou pela função de máxima verossimilhança, embora ambos os métodos sejam eficazes, o método da máxima verossimilhança é mais utilizado pois é mais eficiente. Maiores detalhes sobre tais métodos, consultar Gujarati e Porter (2011) e Bueno (2008).

De acordo com Box e Jenkins (1976), a inclusão de muitos parâmetros no modelo ajustado pode ser prejudicial, pois o mesmo deve ser o mais parcimonioso possível. Para decidir sobre a inclusão ou não de parâmetros, os critérios *Akaike Information Criteria* – AIC (AKAIKE, 1973) e *Bayesian Information Criteria* – BIC (SCHWARZ, 1978) são utilizados. Tais critérios são considerados penalizadores, pois levam em consideração o número de parâmetros dos modelos e a variância dos erros gerados, dessa forma o modelo que apresentar menores valores para os critérios e AIC e BIC terá o melhor ajuste (MORETTIN, 2008). Os critérios de AIC e BIC são definidos pelas equações (11) e (12):

$$AIC(p, q) = \ln \sigma_{p,q}^2 + \frac{2(p+q)}{n} \quad (11)$$

$$BIC(p, q) = \ln \sigma_{p,q}^2 + (p+q) \frac{\ln(n)}{n} \quad (12)$$

Onde: p e q são os parâmetros conhecidos, n é o tamanho da amostra, \ln o logaritmo neperiano e σ^2 a variância estimada dos erros.

A validação do modelo consiste em verificar o ajuste ao comportamento real da série. A sequência de erros pelo modelo ajustado deve possuir características de ruído branco, com média zero, variância constante e não autocorrelacionados $RB \sim (0, \sigma^2)$ (BUENO, 2008). A análise do ajuste do modelo aos dados reais é realizada por meio de medidas de acurácia. As medidas de acurácia consideradas nesta pesquisa são descritas no Quadro 2.

Quadro 2 – Medidas de acurácia

Sigla	Descrição	Equação
MAE	Erro Médio Absoluto	$\frac{\sum_{t=1}^n \varepsilon_t }{n}$ (13)
MAPE	Erro Percentual Médio Absoluto	$\frac{\sum_{t=1}^n \varepsilon_t/Z_t \cdot 100}{n}$ (14)
U-Theil	Coefficiente de U-Theil	$\frac{\sqrt{\sum_{t=1}^n (\varepsilon_t)^2}}{\sqrt{\sum_{t=1}^n (Z_t - Z_{t-1})^2}}$ (15)

Fonte: Adaptado de Bueno (2008).

Onde: ε_t = Erro de previsão no instante t ; n = Número de observações; Z_t = Valor real no tempo t e $t = 1, 2, \dots, n$.

A última etapa consiste comumente em um dos objetivos principais da aplicação da metodologia de Box-Jenkins: a realização de previsões. A definição do horizonte de previsão, assim como os métodos de verificação da acurácia das previsões dependem da natureza do estudo realizado (HYNDMAN; ATHANASOPOULOS, 2018). Previsões que abrangem até três passos à frente, são consideradas de curto prazo. Se o horizonte for maior que 20 períodos é considerado longo prazo. Se for realizada em algum período intermediário entre os citados, a previsão é considerada de médio prazo (JOHNSON; KING, 1988).

3 MATERIAIS E MÉTODOS

Neste capítulo são descritas as variáveis consideradas no estudo e os procedimentos metodológicos utilizados nesta pesquisa.

3.1 DESCRIÇÃO DAS VARIÁVEIS

Para realização desta pesquisa, foram consideradas as seguintes variáveis: Produção Brasileira de Biodiesel (em m³); Produção Brasileira de Etanol (em m³); Produção Brasileira de Gás Natural (em m³); Produção Brasileira de Petróleo (em m³); Exportações Brasileiras de Diesel (em m³); Importações Brasileiras de Diesel (em m³); Exportações (em milhões de reais); Importações (em milhões de reais); Produto Interno Bruto (em milhões de reais); Índice Geral de Preços ao Mercado (IGPM); Índice de Preços ao Consumidor Amplo (IPCA); Preço do Biodiesel; Preço do Óleo de Soja; Preço da Soja em Grão; e o Volume de Vendas de Biodiesel.

A coleta das observações sobre a produção de combustíveis, exportações e importações de diesel, preço do biodiesel e vendas de biodiesel foi realizada por meio das informações disponibilizadas nos relatórios da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (<<http://www.anp.gov.br/>>) (ANP, 2017).

Enquanto as informações sobre as variáveis macroeconômicas PIB, exportações, importações, IGPM e IPCA foram coletadas no site do Instituto de Pesquisa Econômica Aplicada (<<http://www.ipeadata.gov.br/>>) (IPEA, 2017).

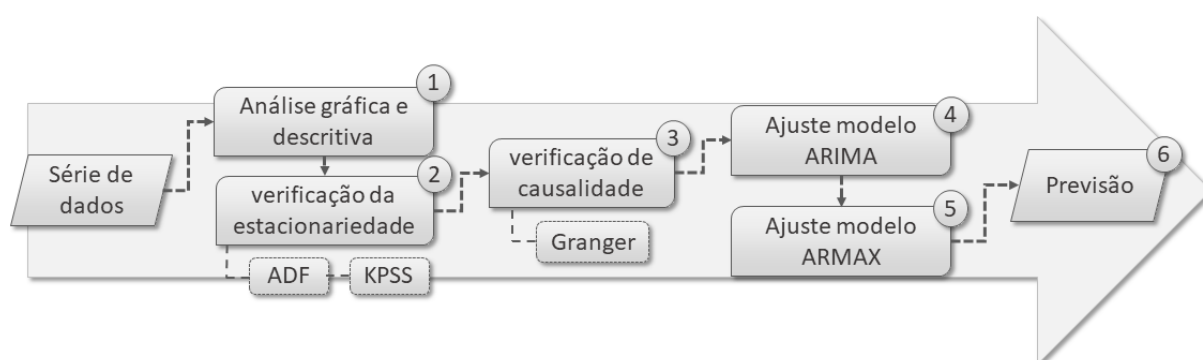
As observações sobre o preço do óleo de soja e o preço da soja em grão foram coletadas também no site do Instituto de Pesquisa Econômica Aplicada (IPEA), sendo dados advindos da secretaria da agricultura e abastecimento do estado do Paraná (SEAB-PR).

As observações utilizadas nesse estudo são de periodicidade mensal, correspondente ao período de janeiro de 2012 a dezembro de 2017, totalizando 72 observações para cada série, sendo utilizadas 66 observações para o ajuste dos modelos e reservadas as seis últimas observações para o cálculo dos erros de previsão. Para tanto, a variável produção de biodiesel foi considerada como variável resposta e as demais foram consideradas como entradas exógenas para ajuste do modelo ARMAX.

3.2 PROCEDIMENTOS METODOLÓGICOS

Para atingir os objetivos propostos, o estudo foi executado em seis etapas: (i) análise gráfica e descritiva; (ii) verificação da estacionariedade; (iii) verificação da relação de causalidade; (iv) estimação dos parâmetros dos modelos ARIMA concorrentes; (v) estimação dos parâmetros do modelo ARMAX; (vi) previsão e cálculo das medidas de acurácia para o modelo ajustado. O detalhamento de cada etapa é apresentado na sequência na Figura 2.

Figura 2 – Etapas dos Procedimentos Metodológicos



Fonte: Elaborado pela autora.

Etapa 1 – Análise gráfica e descritiva das séries em estudo para conhecer o comportamento temporal das variáveis pesquisadas.

Etapa 2 – Testes de raiz unitária Augmented Dickey-Fuller (ADF) e Kwiatkowski-Phillips-Schimidt-Shin (KPSS); para verificar a estacionariedade das séries.

Etapa 3 – Identificadas das relações de causalidade entre as variáveis por meio do teste de causalidade de Granger.

Etapa 4 - Estimação dos parâmetros dos modelos ARIMA concorrentes e selecionado o melhor modelo de acordo com os critérios AIC e BIC, e atendendo as condições de estacionariedade e invertibilidade, com todos os parâmetros significativos.

Etapa 5 – Estimação dos parâmetros do modelo ARMAX, com a inclusão das variáveis exógenas significativas, de acordo com o número de defasagens no qual as variáveis apresentaram parâmetros significativos.

Etapa 6 – Previsão de curto prazo, com um horizonte de seis meses para o período de julho a dezembro de 2017 da variável produção de biodiesel, de acordo com o modelo ARMAX ajustado, e cálculo das medidas de acurácia *Mean Absolut Error (MAE)*, *Mean Absolut Percentage Error (MAPE)* e *U-Theil* para avaliar a qualidade do modelo ajustado.

Como recurso computacional para tratamento, análise e modelagem dos dados foi utilizado o software Eviews 9 SV. E os testes estatísticos foram realizados considerando-se o nível de significância $\alpha = 0,05$.

Na seção seguinte, são apresentados os resultados e discussão acerca do processo de modelagem e as contribuições dessa pesquisa em relação ao objeto de estudo, ou seja, a produção brasileira de biodiesel.

4 RESULTADOS E DISCUSSÃO

A análise descritiva das variáveis, utilizadas neste estudo, foi realizada a partir da interpretação das medidas descritivas de tendência central (média, mediana, máximo e mínimo) e de dispersão (desvio-padrão e coeficiente de variação) apresentadas na Tabela 1, e dos gráficos das séries originais apresentados nas Figuras 3, 4 e 5.

Tabela 1 – Estatística descritiva das variáveis: Produção de Biodiesel, Etanol, Gás Natural e Petróleo; Exportação e Importação de Diesel; Índice Geral de Preços ao Mercado (IGPM) e Índice de Preços ao Consumidor Amplo (IPCA); Produto Interno Bruto (PIB), Exportações e Importações; Preço do Biodiesel, Preço do Óleo de Soja, Preço da Soja em Grão e Volume de Vendas de Biodiesel, no período de janeiro de 2012 a dezembro de 2017.


	Média	Mediana	Máximo	Mínimo	Desvio padrão	CV (%)
Produção Biodiesel	292876,2	301518,3	409344,0	182372,2	55720,0	19,0
Produção Etanol	2316783,1	2621608,2	4615080,1	184482,5	1447643,1	62,5
Produção Gás Natural	2764383,8	2821925,1	3565186,3	1946002,6	454714,6	16,4
Produção Petróleo	11220469,1	11247430,1	13454317,4	8980299,0	1237772,3	11,0
Exportação Diesel	30485,9	21868,3	147188,4	0,0	33861,7	111,1
Importações Diesel	796416,8	775001,4	1586762,5	28618,9	327689,5	41,1
Preço Óleo de Soja	2557,8	2556,5	3243,6	1917,6	339,9	13,3
Preço Soja em Grão	61,5	61,2	81,0	42,4	7,0	11,3
Preço Biodiesel	2247,3	2213,6	2855,1	1856,7	277,5	12,3
Vendas Biodiesel	4732864,0	4733942,2	5732736,7	3927754,9	375110,3	7,9
Exportações	18108,6	18178,7	23213,9	11237,7	2706,5	14,9
Importações	15018,1	15118,5	20378,0	9155,0	3537,4	23,6
IGPM	0,5	0,4	1,9	-1,1	0,6	132,1
IPCA	0,5	0,5	1,3	-0,2	0,3	60,2
PIB	480173,3	484927,2	588404,0	367177,3	52602,8	11,0

Fonte: elaborado pela autora.

Na Tabela 1 são apresentadas as medidas descritivas das variáveis em estudo. Por meio da observação das medidas de tendência central, pode-se verificar que a Produção de Petróleo possui a maior média, 11.220.469,1 m³, seguida da Produção de Gás Natural, 2.764.383,8 m³, da Produção de Etanol, 2.316.783,1 m³, e da Produção de Biodiesel, com a menor média, 292.876,2 m³. Portanto pode-se afirmar que há um predomínio das fontes não-renováveis na produção de combustíveis, enquanto as fontes renováveis como o Etanol e Biodiesel possuem uma pequena participação. Porém, ao observar a Figura 1, verifica-se que a participação do biodiesel na produção de combustíveis apresenta uma tendência de crescimento ao longo do período analisado.

Verifica-se que a Produção de Etanol apresenta períodos acentuados de sazonalidade, os quais podem ser atribuídos à cana-de-açúcar, tipo de matéria-prima predominantemente utilizado na produção desse combustível. Além disso, a Produção de Etanol apresenta um coeficiente de variação de 62,5% o qual pode referir-se ao fato de, mesmo o Brasil tendo uma experiência de sucesso e um crescimento acentuado da produção na última década, alguns aspectos como as variações no clima contribuem para uma crise da agroindústria canavieira resultando em baixa lucratividade e dificuldades financeiras das indústrias dessa cadeia produtiva (SANTOS et al., 2016).

Figura 3 – Gráficos das séries mensais da Produção de Biodiesel, Produção de Etanol, Produção de Gás Natural e Produção de Petróleo, no Brasil, no período de janeiro de 2012 à dezembro de 2017

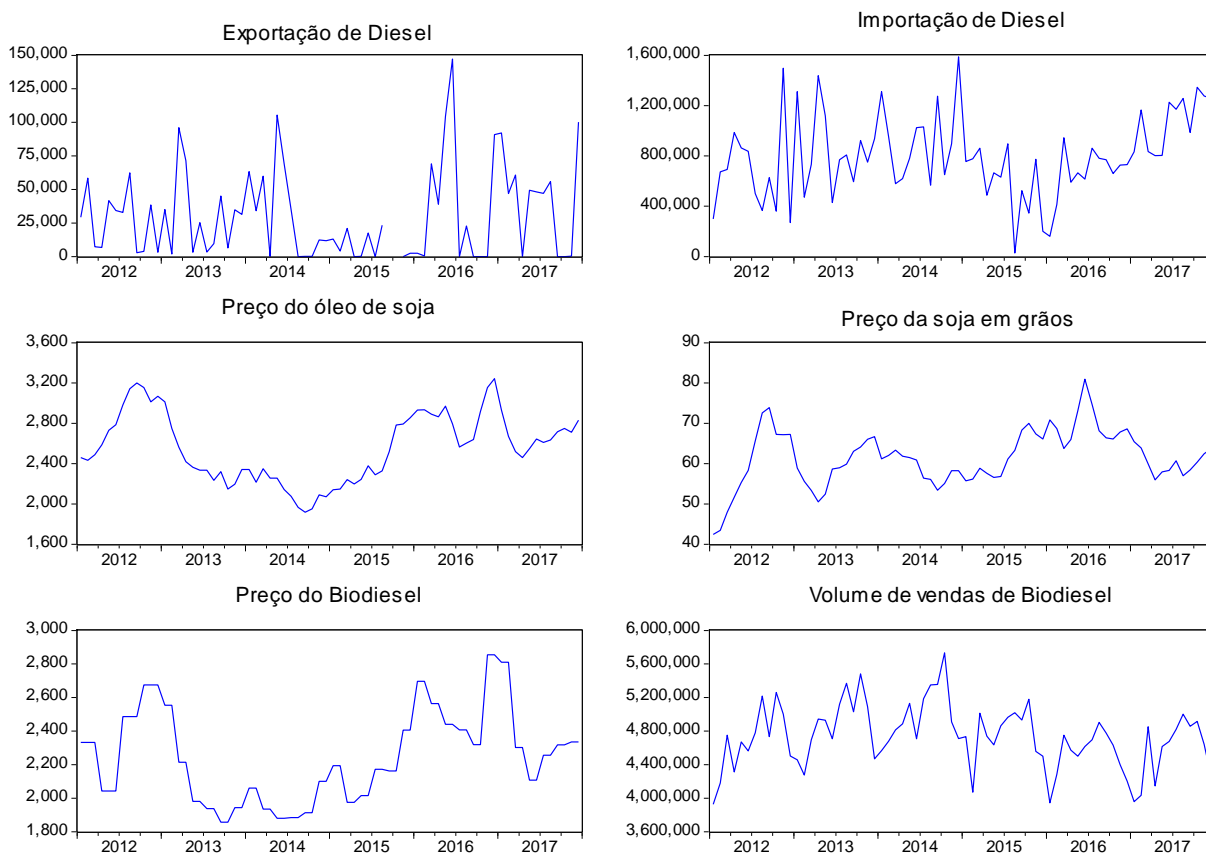


Fonte: Agência Nacional do Petróleo, Gás Natural e Biocombustíveis.

A Produção de Biodiesel apresenta um coeficiente de variação de 19%, sendo o segundo maior entre as variáveis de produção de combustível, seguida respectivamente da Produção de Gás Natural, com 16,4% e da Produção de Petróleo, com 11%.

Em relação às variáveis relacionadas à matéria-prima soja (Figura 4), analisada nesse estudo por ser predominantemente utilizada para produção de biodiesel no Brasil, pode-se verificar que o Preço do Óleo de Soja apresenta um coeficiente de variação de 13% e uma média de R\$2.557,8 por tonelada. Enquanto o Preço da Soja em Grão apresenta um coeficiente de 11,3% e uma média de R\$ 61,5 por saca de 60 quilos. Na Figura 4 estão apresentadas as variáveis Exportações de Diesel, Importações de Diesel e Volume de Vendas de Biodiesel. No que diz respeito a variação dessas variáveis, pode-se verificar que apresentam, respectivamente, coeficiente de variação de 111,1%, 41,1% e 7,9%.


Figura 4 – Gráficos das séries Exportações de Diesel, Importações de Diesel, Preço do Óleo de Soja, Preço da Soja em Grão, Preço do Biodiesel e Volume de Vendas de Biodiesel, no Brasil, no período de janeiro de 2012 a dezembro de 2017



Fonte: Agência Nacional do Petróleo, Gás Natural e Biocombustíveis.

Na Figura 5 estão apresentadas as séries que representam as variáveis macroeconômicas Exportações, Importações, Índice Geral de Preços do Mercado (IGPM), Índice de Preços ao Consumidor Amplo (IPCA) e Produto Interno Bruto (PIB).

Figura 5 – Gráficos das séries Exportações, Importações, Índice Geral de Preços do Mercado (IGPM), Índice de Preços ao Consumidor Amplo (IPCA) e PIB do Brasil, no período de janeiro de 2012 à dezembro de 2017.



Fonte: Instituto de Pesquisa Econômica Aplicada.

A seguir, na Tabela 2, são apresentados os resultados dos testes de raiz unitária ADF e KPSS para as séries em nível e em primeira diferença.

Tabela 2 – Resultados dos testes de raiz unitária ADF e KPSS

(continua)

	ADF ^a (t-stat)		KPSS ^b (LM-stat)	
	Em nível	$d=1$	Em nível	$d=1$
Prod. Biodiesel	-1,929287	-9,138741	0,988404	0,111443
Prod. Etanol	-2,279176	-8,690925	0,481872	0,393424
Prod. Gás natural	-0,891421	-13,78829	1,116374	0,088890
Prod. Petróleo	-0,514797	-3,291419	1,008034	0,183757
Exportação Diesel	-6,313304	–	0,141144	–
Importação Diesel	-7,067583	–	0,214366	–

Tabela 2 – Resultados dos testes de raiz unitária ADF e KPSS

(conclusão)

	ADF ^a (t-stat)		KPSS ^b (LM-stat)	
Preço Óleo de Soja	-2,229467	-5,500650	0,574294	0,085884
Preço Soja Grão	-4,023392	–	0,284892	–
Preço Biodiesel	-2,226141	-5,376592	0,662209	0,057726
Vendas Biodiesel	-4,886779	–	0,253165	–
Exportações	-1,965532	-4,428319	0,581721	0,049095
Importações	-0,772912	-10,05649	0,885693	0,137598
IGPM	-4,343848	–	0,163759	–
IPCA	-3,652506	–	0,201917	–
PIB	-2,891370	-3,478067	0,680159	0,143793

$\alpha = 0,05$; ^a Valor crítico de Mackinnon (1996) = -2,903566; ^b Valor crítico de Kwiatkowski et al. (1992) = 0,463000
 Fonte: elaborado pela autora.

Após a aplicação dos testes de raiz unitária, foi realizado o teste de Causalidade de Granger para verificar a presença de relação entre as variáveis. Averiguou-se o sentido da causalidade unidirecionais ou bidirecionais, conforme resultados apresentados na Tabela 3.

Tabela 3 – Resultado do teste de Causalidade de Granger

Hipótese nula	F-stat	p-valor
$\Delta(\text{Produção Biodiesel}) \leftrightarrow \Delta(\text{Preço óleo de soja})$	327,519	0,0442
$\Delta(\text{Produção Biodiesel}) \leftrightarrow \Delta(\text{Produção Petróleo})$	353,717	0,0349
$\Delta(\text{Produção Biodiesel}) \rightarrow (\text{Preço soja em grão})$	315,096	0,0495
$\Delta(\text{Produção Etanol}) \leftrightarrow (\text{Vendas Biodiesel})$	544,375	0,0066
$\Delta(\text{Produção Gás Natural}) \rightarrow \Delta(\text{Produção Biodiesel})$	106,173	0,0001
$\Delta(\text{Produção Gás Natural}) \rightarrow \Delta(\text{Preço Biodiesel})$	823,547	0,0007
$\Delta(\text{Produção Gás Natural}) \rightarrow (\text{Vendas Biodiesel})$	418,204	0,0196
$\Delta(\text{Importação}) \rightarrow \Delta(\text{Preço Biodiesel})$	503,639	0,0093
$\Delta(\text{Preço óleo de soja}) \rightarrow \Delta(\text{Preço Biodiesel})$	139,170	0,0001
$\Delta(\text{Preço Biodiesel}) \rightarrow \Delta(\text{Produção Biodiesel})$	367,867	0,0307
$\Delta(\text{Preço Biodiesel}) \rightarrow \Delta(\text{Produção Etanol})$	586,966	0,0046
$\Delta(\text{Preço Biodiesel}) \rightarrow \Delta(\text{PIB})$	680,904	0,0021
$\Delta(\text{Preço Biodiesel}) \rightarrow (\text{IGPM})$	446,211	0,0153
$\Delta(\text{Produção Petróleo}) \rightarrow \Delta(\text{Preço Biodiesel})$	469,942	0,0125
$(\text{Vendas Biodiesel}) \leftrightarrow \Delta(\text{Produção Petróleo})$	538,579	0,0069
$\Delta(\text{PIB}) \rightarrow \Delta(\text{Produção Biodiesel})$	357,905	0,0336
$\Delta(\text{PIB}) \leftrightarrow (\text{Vendas Biodiesel})$	641,231	0,0029
$(\text{Exportação Diesel}) \rightarrow \Delta(\text{Preço óleo de soja})$	106,502	0,0001
$(\text{IGPM}) \rightarrow \Delta(\text{Preço óleo de soja})$	363,210	0,0321
$(\text{Vendas Biodiesel}) \rightarrow \Delta(\text{Exportação})$	519,849	0,0081
$(\text{Vendas Biodiesel}) \rightarrow \Delta(\text{Preço Biodiesel})$	368,071	0,0307
$(\text{Vendas Biodiesel}) \rightarrow (\text{IPCA})$	540,641	0,0067


O símbolo \rightarrow indica causalidade unidirecional; O símbolo \leftrightarrow indica causalidade bidirecional. H_0 : série “X” não causa série “Y” no sentido de Granger; H_1 : série “X” causa série “Y” no sentido de Granger; $\alpha = 0,05$.

Fonte: elaborado pela autora.

Considerando os resultados dispostos na Tabela 3, verifica-se que há uma relação significativa de causalidade bidirecional, entre as variáveis Produção de Biodiesel e o Preço do Óleo de Soja, entre Produção de Biodiesel e Produção de Petróleo, entre Produção de Etanol e Vendas de Biodiesel, e entre Produção de Petróleo e Vendas de Biodiesel. Enquanto pode-se verificar uma relação significativa de causalidade unidirecional entre a Produção de Biodiesel e o Preço da Soja em Grão, entre a Produção de Gás Natural e a Produção de Biodiesel, entre a Produção de Gás Natural e o Preço do Biodiesel, entre a Produção de Gás Natural e as Vendas de Biodiesel. Por fim destaca-se a relação significativa de causalidade unidirecional entre o PIB e a Produção de Biodiesel, além da relação significativa de causalidade bidirecional entre o PIB e as Vendas de Biodiesel.

Na Figura 6 são apresentadas a série original da Produção de Biodiesel (em m³) no Brasil, a Função de Autocorrelação (ACF) e a Função de Autocorrelação Parcial (PACF), na qual se pode observar uma tendência de crescimento nos períodos de 2014 a 2016, com um declínio acentuado em 2016 e uma tendência de crescimento no período de 2017 a 2018. Conforme a ACF, pode-se verificar que a série não apresenta um decaimento rápido até o *lag* 12 indicando que a série possui autocorrelação significativa, enquanto ao observar a PACF verifica-se a existência de apenas um parâmetro significativo no *lag* 1.

Figura 6 – Série mensal original da Produção de Biodiesel; Função de Autocorrelação (ACF) e Função de Autocorrelação Parcial (PACF)



Fonte: elaborado pela autora.

Na Tabela 4 são apresentados os parâmetros dos modelos ARIMA concorrentes ajustados e os respectivos p-valores, bem como os valores dos critérios penalizadores AIC (*Akaike Information Criteria*) e BIC (*Bayesian Information Criteria*), e a informação de ruído branco (RB).

Tabela 4 – Modelos ARIMA concorrentes

SARIMA (2,1,2) (1,0,0) ₁₂				
Parâmetro	p-valor	AIC	BIC	RB
$\phi_2 = 0,645859$	0,0347*	23,01184	23,14033	Sim
$\theta_2 = -0,814231$	0,0011*			
$\Phi_{12} = 0,279473$	0,0372*			
SARIMA (1,1,0) (1,0,0) ₁₂				
Parâmetro	p-valor	AIC	BIC	RB
$\phi_1 = -0,101565$	0,4492 ^{ns}	23,07029	23,16982	Sim
$\Phi_{12} = 0,253311$	0,0495*			
ARIMA (1,1,1)				
Parâmetro	p-valor	AIC	BIC	RB
$\phi_1 = 0,588207$	0,0393*	23,06894	23,16847	Não
$\theta_1 = -0,804143$	0,0006**			
ARIMA (2,1,0)				
Parâmetro	p-valor	AIC	BIC	RB
$\phi_1 = -0,109418$	0,4317 ^{ns}	23,09201	23,19154	Sim
$\phi_2 = -0,173151$	0,1229 ^{ns}			
ARIMA (0,1,2)				
Parâmetro	p-valor	AIC	BIC	RB
$\theta_1 = -0,179920$	0,2573 ^{ns}	23,07186	23,17139	Sim
$\Theta_2 = -0,229263$	0,0535 ^{ns}			

*Significativo a 5%; **Significativo a 1%; ^{ns} Não significativo a 5%.

Fonte: elaborado pela autora.

Pode-se verificar que o modelo SARIMA (2,1,2)(1,0,0)₁₂ é o mais adequado para descrever o comportamento e as características da série de Produção de Biodiesel, pois apresenta todos os parâmetros significativos (p-valor < 0,05), apresenta os menores valores de AIC e BIC, bem como apresenta os resíduos com característica de ruído branco, ou seja, não autocorrelacionados, com média aproximadamente zero e variância constante.

A partir do modelo SARIMA (2,1,2)(1,0,0)₁₂, para a estimação dos parâmetros do modelo ARMAX, foram incluídas as seguintes variáveis significativas como exógenas, de acordo com o resultado do teste de causalidade de Granger: Preço do Óleo de Soja, Produção de Petróleo, Preço da Soja em Grão, Produção de Gás Natural, Preço do Biodiesel e PIB. As

séries foram testadas com defasagem de até 6 *lags* e, após diversas combinações de inclusão dessas variáveis nos respectivos *lags*, os seguintes parâmetros foram significativos: $\Delta(\text{Preço Óleo de Soja})_{(t-3)}$, $\Delta(\text{Produção de Petróleo})_{(t-5)}$, $\Delta(\text{PIB})_{(t-2)}$, $\Delta(\text{Produção de Gás Natural})_{(t-5)}$ e $\Delta(\text{Produção de Gás Natural})_{(t-2)}$. Dessa forma, verificou-se quais das variáveis exógenas causam interferência na Produção de Biodiesel em até 6 períodos passados.

Na Tabela 5 são apresentados os parâmetros do modelo SARIMAX (0,1,2)(1,0,0)₁₂ $\Delta(\text{Preço do Óleo de Soja})_{t-3}$ $\Delta(\text{Prod. Petróleo})_{t-5}$ $\Delta(\text{PIB})_{t-2}$ $\Delta(\text{Prod. Gás Natural})_{t-2;t-5}$ ajustado, os respectivos os p-valores, os critérios penalizadores AIC e BIC, e a informação de ruído branco (RB).

Tabela 5 – Modelo ARMAX ajustado para previsão da produção brasileira de biodiesel

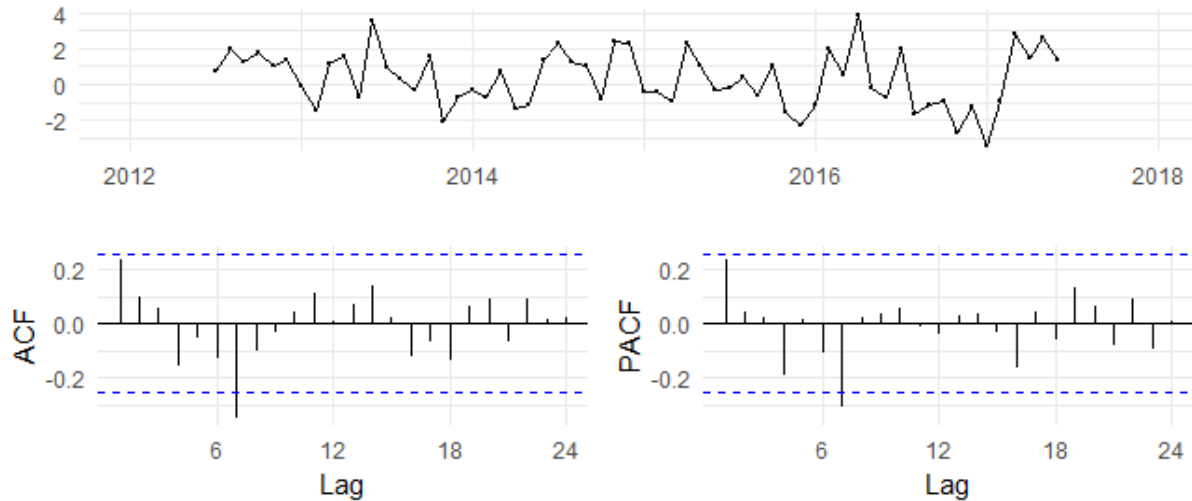
SARIMAX (0,1,2)(1,0,0) ₁₂ $\Delta(\text{OIL})_{t-3}\Delta(\text{PET})_{t-5}\Delta(\text{PIB})_{t-2}\Delta(\text{GAS})_{t-2;t-5}$				
Parâmetro	p-valor	AIC	BIC	RB
$\theta_2 = -0,717130$	<0,0001	22,55884	22,83567	Sim
$\Phi_{12} = 0,614684$	0,0001			
$\Delta(\text{Preço do Óleo de Soja})_{t-3} = -31,56109$	0,0204			
$\Delta(\text{Prod. Petróleo})_{t-5} = 0,022831$	0,0013			
$\Delta(\text{PIB})_{t-2} = -0,526705$	0,0041			
$\Delta(\text{Prod. Gás Natural})_{t-2} = 0,098316$	<0,0001			
$\Delta(\text{Prod. Gás Natural})_{t-5} = -0,084318$	0,0007			

Fonte: elaborado pela autora.

O modelo SARIMAX (0,1,2)(1,0,0)₁₂ $\Delta(\text{OIL})_{t-3}\Delta(\text{PET})_{t-5}\Delta(\text{PIB})_{t-2}\Delta(\text{GAS})_{t-2;t-5}$ ajustado apresenta as variáveis exógenas Preço do Óleo de Soja com três defasagens, Produção de Petróleo com cinco defasagens, PIB com duas defasagens e Produção de Gás Natural com duas e cinco defasagens. Entre as variáveis exógenas, a Produção de Gás Natural com duas defasagens (p-valor < 0,0001), foi a mais significativa do modelo e apresentou influência positiva (0,098316) na Produção de Biodiesel. Porém, apresentou influência negativa (-0,084318) com cinco defasagens (p-valor = 0,0007). Em seguida estão as variáveis Produção de Petróleo, com cinco defasagens (p-valor = 0,0013) e influência positiva (0,022831), o PIB com duas defasagens (p-valor = 0,0041) e influência negativa (-0,526705), e Preço do Óleo de Soja com três defasagens (p-valor = 0,0204) e influência negativa (-31,56109).

Na Figura 7 é apresentado o gráfico dos resíduos do modelo SARIMAX (0,1,2)(1,0,0)₁₂ $\Delta(\text{OIL})_{t-3}\Delta(\text{PET})_{t-5}\Delta(\text{PIB})_{t-2}\Delta(\text{GAS})_{t-2;t-5}$, a ACF e a PACF dos resíduos.

Figura 7 – Resíduos do modelo ARMAX ajustado, Função de Autocorrelação (ACF) e Função de Autocorrelação Parcial (PACF) dos resíduos do modelo ARMAX

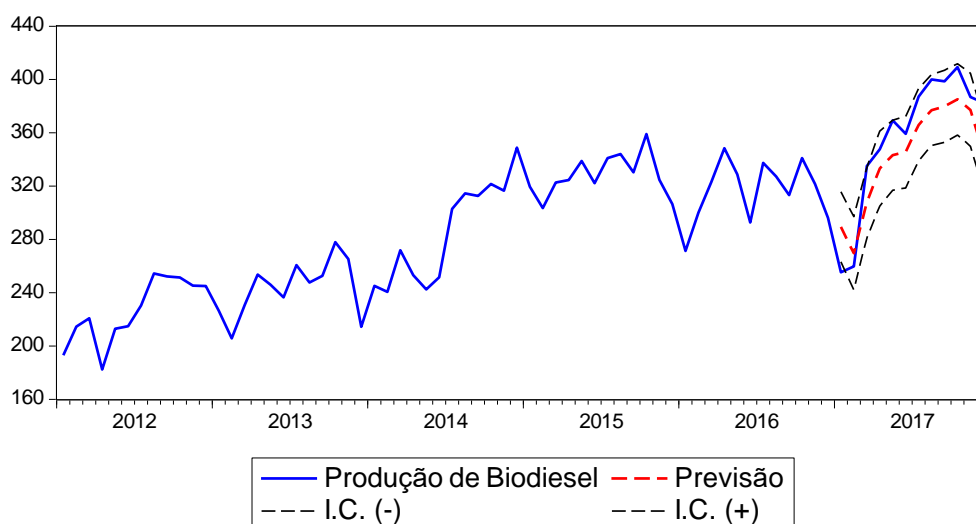


Fonte: elaborado pela autora.

Verifica-se, por meio do gráfico dos resíduos, que os mesmos estão distribuídos com média zero e variância constante. E por meio da ACF e PACF verifica-se que os resíduos do modelo apresentam características de ruído branco, ou seja, não autocorrelacionados.

Ao observar que o modelo ajustado atendeu aos requisitos da metodologia de Box-Jenkins, apresentando ruído branco, foi então realizada a previsão *in-sample*, com finalidade de verificar a eficácia do modelo como previsor do comportamento futuro da série de Produção de Biodiesel, conforme Figura 8.

Figura 8 – Previsão da Produção de Biodiesel (*in sample*) por meio do modelo SARIMAX $(0,1,2)(1,0,0)_{12}\Delta(OIL)_{t-3}\Delta(PET)_{t-5}\Delta(PIB)_{t-2}\Delta(GAS)_{t-2;t-5}$



Fonte: elaborado pela autora.

Na Tabela 6 são apresentados os valores previstos seis passos à frente, de acordo com modelo SARIMAX $(0,1,2)(1,0,0)_{12}\Delta(OIL)_{t-3}\Delta(PET)_{t-5}\Delta(PIB)_{t-2}\Delta(GAS)_{t-2;t-5}$ ajustado, com os valores originais e os intervalos de confiança. Ao verificar os valores da Tabela 6 pode-se afirmar que o modelo captou bem o comportamento da série em estudo, pois os valores originais de julho a dezembro de 2017, encontram-se entre os limites de previsão do modelo ajustado.

Tabela 6 - Valores previstos de acordo com o modelo SARIMAX $(0,1,2)(1,0,0)_{12}\Delta(OIL)_{t-3}\Delta(PET)_{t-5}\Delta(PIB)_{t-2}\Delta(GAS)_{t-2;t-5}$

Período	Valor Real	Valor Previsto	Limite Superior	Limite Inferior
Julho/2017	387236,43	365783,32	338648,91	392917,73
Agosto/2017	399996,84	377044,72	350469,71	403619,74
Setembro/2017	398707,42	379845,67	352763,87	406927,48
Outubro/2017	409343,99	385099,95	358325,53	411874,36
Novembro/2017	386941,09	377219,73	349883,30	404556,15
Dezembro/2017	382671,30	345355,24	318408,50	372301,98

Fonte: elaborado pela autora.

As medidas de acurácia MAPE, MAE e U-Theil foram calculadas a partir da previsão *in-sample* realizada, conforme a Tabela 7. O modelo apresentou um valor menor que 1 para a estatística de U-Theil, indicando que o modelo ajustado é melhor predictor em relação a uma previsão ingênua. Para as estatísticas de MAPE e MAE, os valores calculados demonstram

baixo erro, qualificando o modelo como um bom previsor do comportamento futuro da Produção de Biodiesel no Brasil.

Tabela 7 – Medidas de Acurácia do modelo SARIMAX (0,1,2)(1,0,0)₁₂ $\Delta(\text{OIL})_{t-3}\Delta(\text{PET})_{t-5}$
 $\Delta(\text{PIB})_{t-2} \Delta(\text{GAS})_{t-2;t-5}$

SARIMAX (0,1,2)(1,0,0)₁₂$\Delta(\text{OIL})_{t-3}\Delta(\text{PET})_{t-5}$ $\Delta(\text{PIB})_{t-2} \Delta(\text{GAS})_{t-2;t-5}$	
MAE	22424,74
MAPE	5,6992%
U-Theil	0,026921

Fonte: elaborado pela autora.

Portanto, pode-se afirmar que o modelo ajustado é adequado para realização de previsões futuras. Uma vez que a Produção de Biodiesel pode ser explicada pelos seus próprios valores defasados, assim como pelas variáveis exógenas consideradas significativas nesse estudo, o modelo proposto permitiu a realização de previsões acuradas com embasamento científico, dentro dos critérios metodológicos propostos na literatura de séries temporais.

Em estudos semelhantes encontrados na literatura, Melikoglu (2014) utilizou um conjunto de modelos de regressão (linear, quadrática, exponencial, gaussiana e de Lorentz) para prever a demanda por combustíveis de transporte rodoviário na Turquia entre 2013 e 2023, entre os combustíveis foram considerados o bioetanol, biodiesel, gasolina e o gás natural. Os resultados dos modelos ajustados sugeriram que, em 2023, o consumo anual de gasolina na Turquia pode diminuir abaixo de 2,0 milhões de m³, enquanto o consumo de diesel e gás natural pode subir para 16,4 e 8,8 milhões de m³, respectivamente. As previsões realizadas também sugeriram que o aumento do consumo de diesel e gás natural seria muito maior do que a média global esperada.

Nesse sentido, uma observação importante a destacar é de que no estudo de Melikoglu (2014), o autor considerou a variável consumo, ou seja, demanda por combustíveis, de origem renovável e não-renovável, no entanto, no caso da presente pesquisa, optou-se por realizar a previsão e o estudo do comportamento temporal da variável produção, ou seja, oferta de biodiesel.

Os resultados desse autor, expõem um aumento no consumo de diesel, o que pode ser apontado como uma oportunidade para a expansão do mercado de produtos relacionados a esse segmento, como por exemplo o biodiesel, o qual pode entrar na pauta de discussão das políticas de fomento ao uso de óleos vegetais adicionados ao óleo diesel ofertado para a população dos países consumidores desse combustível.

Melikoglu (2014) ainda enfatiza que, em geral, os combustíveis utilizados para transporte rodoviário são à base de petróleo sendo mais poluentes, aumentam a pegada de carbono da Turquia e contribuem para aumentar o déficit comercial. Para lidar com isso, o governo decidiu, no início de 2013, misturar gradualmente biocombustíveis aos combustíveis utilizados no transporte rodoviário. E, para atingir as metas do governo até 2023, as previsões sugerem que seriam necessários 0,3 milhões de m³ de bioetanol e 1,4 milhões de m³ de biodiesel. O pesquisador também destaca que, se o preço da gasolina continuar aumentando, mais consumidores escolheriam o gás natural como combustível ou comprariam veículos a diesel de baixo consumo, conseqüentemente, a demanda de biodiesel poderia aumentar para 3,4 milhões de m³, em 2023.

Um ponto em comum com o referido estudo, está no fato de que o autor também enfatiza uma tendência no aumento da participação de biocombustíveis na matriz energética ao considerar que estas possam ser influenciadas por mudanças em variáveis de cunho econômico, como por exemplo o preço dos demais combustíveis ofertados ao consumidor, que podem motivar a sua escolha por determinado tipo de combustível. Além disso, uma das razões para a adoção de políticas de fomento ao uso de biocombustíveis, pode estar relacionada ao engajamento do governo em reduzir a poluição causada pelos combustíveis de origem fóssil.

Outra pesquisa abordou essa temática, realizada por Brorsen (2015), na qual foi ajustado um modelo de combinação de previsão, baseado nas previsões individuais dos modelos de tendência linear e ARIMA para a produção do biodiesel nos EUA, com o objetivo de responder o que seria uma meta razoável para produção de biodiesel e de biocombustíveis. Dessa forma, o objetivo foi projetar a quantidade de matéria-prima disponível para a produção de biodiesel sem causar um aumento significativo de preços, e investigar se seria coerente aumentar o diesel à base de biomassa e a produção de biocombustível em 100 milhões de litros e 500 milhões de litros por ano nos próximos anos.

O autor considerou o óleo de soja, por ser uma das principais matérias-primas para produção do biodiesel, e o óleo de canola, outra fonte explorada extensivamente por conta de render um biodiesel de qualidade superior às demais oleaginosas. A resposta encontrada por Brorsen (2015) foi a de que seria necessário aumentar a produção de biodiesel em 29 milhões de litros em 2016, nos EUA, mas previu uma redução da disponibilidade de matéria-prima nos anos seguintes.

Na pesquisa realizada por Brorsen (2015), que também considerou a produção de biodiesel para realizar uma previsão, observa-se que o autor buscou contribuir com informações pertinentes aos tomadores de decisão no que tange ao planejamento do setor de

biocombustíveis. Pois assim como no presente estudo, verifica-se uma tendência de aumento da produção de biocombustíveis, no entanto a questão a ser compreendida a partir de tal constatação, reside no fato de conhecer também a disponibilidade de matéria-prima necessária para suprir o aumento da produção e consumo de biocombustíveis.

No estudo desenvolvido por Bentivoglio, Finco e Bacchi (2016), apresentou-se o modelo Vetorial de Correção de Erros (VEC) para estudar a interdependência entre a produção de biocombustíveis, combustíveis e preços de alimentos no Brasil, utilizando o modelo ajustado para realizar previsões e analisar a causalidade entre as variáveis. Seus resultados apontam que o etanol e a gasolina, bem como os níveis de preço do etanol e do açúcar possuem uma relação de equilíbrio a longo prazo. As pesquisadoras também apontaram a existência de uma relação positiva entre os preços do etanol e do açúcar, sendo observado que os preços do etanol aumentaram com um aumento nos preços da gasolina e do açúcar.

Na presente pesquisa, assim como em Bentivoglio, Finco e Bacchi (2016), também foram consideradas as relações de causalidade entre a produção dos biocombustíveis e o preço da matéria-prima, possibilitando dessa forma, realizar uma análise da conjuntura em que estão ocorrendo tais relações. Ainda é importante destacar que nesse estudo, uma das variáveis que apresentou relação direta e influência negativa sobre a produção de biodiesel, foi o preço do óleo de soja.

Em outra investigação recente, de autoria de Bhutto et al. (2017), foi utilizada a modelagem ARIMA para prever o consumo de gasolina no Paquistão, sendo que os autores argumentam que a entrada de fontes de energias renováveis para a substituição das não-renováveis requer um horizonte de previsão de consumo para elaboração de estratégias, por isso ajustaram um modelo com alta acurácia e realizaram uma previsão para o período de 2015 a 2025. Os pesquisadores mostram que o consumo anual de gasolina no setor de transporte pode aumentar de 4,50 Mtep no período entre 2013 e 2014 e, aumentar para 6,21 Mtep entre 2025 e 2026. Portanto, fornecem informações úteis para projetar políticas a favor da substituição da gasolina por etanol, bem como contribuem para que as refinarias estejam atentas ao analisar seus processos de produção e a configuração do seu mix de produtos.

No estudo de Bhutto et al. (2017), também verifica-se que os autores optaram por realizar o estudo do consumo, mas nesse caso de um combustível não-renovável, a gasolina. Porém, esses autores também destacam a relevância do uso de técnicas de previsão como fonte de informação, tanto para a elaboração de políticas de incentivo ao uso de combustíveis renováveis, quanto como ferramentas para o planejamento estratégico do setor privado ligado a produção de combustíveis.

Ainda, entre os estudos examinados, na pesquisa realizada por Ates, Barutcu e Karaosmanoglu (2017), apresentam o uso da modelagem ARMAX para prever a produção anual de bioetanol na Turquia. Sendo que, ao fim do estudo, os autores compararam o modelo ARMAX ajustado aos modelos clássicos ARIMA, obtendo superior acurácia para a modelagem ARMAX por incorporar entradas externas. Os pesquisadores propõe a modelagem para prever a produção potencial anual de trigo, milho, cevada, e beterraba sacarina, que podem ser utilizados como matéria-prima para fabricação de bioetanol de primeira geração. Assim, concluíram que os fornecimentos de cevada e trigo têm um potencial significativo para produzir bioetanol, mas há um conflito em relação ao seu uso primário em alimentos, sementes e consumo de ração.

Assim como no estudo de Ates, Barutcu e Karaosmanoglu (2017), essa pesquisa buscou realizar a previsão da produção de biodiesel considerando a influência de outras variáveis, e consequentemente buscando a maior acurácia do modelo obtido por meio da modelagem ARMAX.

Dessa forma, os resultados da presente pesquisa, convergem para a literatura atual ao explorar o tema do biodiesel, que se apresenta relevante quanto a necessidade de implementações de técnicas avançadas para prever tanto a produção quanto o consumo, assim como de estudar outras variáveis que possam influenciar o comportamento do biodiesel e de outros biocombustíveis. De forma geral, as abordagens discutidas utilizam de modelos quantitativos estatísticos concordando com a eficácia dos modelos de previsão para o gerenciamento de incertezas nesse campo de pesquisa.

5 CONCLUSÃO

O objetivo desse estudo foi analisar a produção brasileira de biodiesel considerando a influência de variáveis macroeconômicas, assim como ajustar um modelo de previsão por meio da modelagem ARMAX. E, para compor o quadro de análise dessa pesquisa, foram utilizadas informações sobre a produção dos biocombustíveis biodiesel e etanol, e dos combustíveis fósseis, gás natural e petróleo, além de variáveis econômicas relacionadas ao setor de combustíveis como exportações, importações, preço de matérias-primas e volume de vendas.

Os resultados dessa pesquisa possibilitaram verificar, por meio do teste de causalidade de Granger, a existência de relações diretas entre a Produção de Biodiesel com o Preço do Óleo de Soja, o Preço da Soja em Grão, a Produção de Petróleo, a Produção de Gás Natural e o PIB. Além disso, o uso da modelagem ARMAX, nessa pesquisa, foi eficiente para verificar o comportamento temporal da produção brasileira de biodiesel, e o modelo ajustado apresentou-se eficaz na realização das previsões.

Espera-se, portanto, que essa investigação torne-se uma contribuição importante na área de estudo, pois os resultados concordam com os desfechos de outros pesquisadores ao considerar que as técnicas de previsão são ferramentas importantes para o planejamento de estratégias no setor de biocombustíveis.

Dessa maneira, afirma-se que o aprimoramento dos métodos para previsão da produção de matérias-primas utilizadas na produção de biodiesel pode também contribuir para a formulação de soluções dos conflitos relacionados aos diversos usos das fontes empregadas na produção de biocombustíveis.

Durante a realização da presente pesquisa algumas limitações foram verificadas, no que diz respeito ao estudo da produção brasileira de biodiesel por meio de modelagem de séries temporais, como a falta de informações referentes a outras variáveis que poderiam ser consideradas nesse estudo, pois não havia disponibilidade das informações, por exemplo sobre preços de outras matérias-primas utilizadas na produção de biodiesel. Outra limitação encontrada foi quanto à abrangência temporal das variáveis consideradas.

Portanto, como sugestões futuras são recomendadas a utilização de outras variáveis pertinentes para o entendimento das conjunções no setor de biodiesel, como preço de matérias-primas e outras variáveis econômicas que possam influenciar a produção desse tipo de combustível. Além de utilizar outras abordagens metodológicas como pesquisa de campo qualitativa, modelos de equações estruturais e análise multivariada.

REFERÊNCIAS

- ADAMS, R. et al. Sustainability-oriented Innovation: A Systematic Review. **International Journal of Management Reviews**, 2016. 180-205.
- AHMAD, A. L. et al. Microalgae as a sustainable energy source for biodiesel production: A review. **Renewable and Sustainable Energy Reviews**, 2011. 584-593.
- AIE. **World Energy Outlook 2017**. <http://www.iea.org/weo/>. 2017.
- AKAIKE, H. Information theory and an extension of the maximum likelihood principle. **2nd International Symposium on Information Theory**, Tsahkadsor, Armenia, USSR, 1973.
- ANP. **Anuário estatístico brasileiro do petróleo, gás natural e biocombustíveis : 2017 - Agência Nacional do Petróleo**. Rio de Janeiro. 2017.
- AQUILA, G. et al. An overview of incentive policies for the expansion of renewable energy generation in electricity power systems and the Brazilian experience. **Renewable and Sustainable Energy Reviews**, 2017. 1090-1098.
- ARANSIOLA, E. F. et al. A review of current technology for biodiesel production: State of the art. **Biomass & Bioenergy**, 2014. 276-297.
- ATABANI, A. E. et al. A comprehensive review on biodiesel as an alternative energy resource and its characteristics. **Renewable and Sustainable Energy Reviews**, 17 Fevereiro 2012. 2070-2093.
- ATES, E. B.; BARUTCU, B.; KARAOSMANOGLU, F. Forecasting on first generation bioethanol production: A comparison of selected linear and non-linear models. **Journal of Renewable and Sustainable Energy**, p. 043101, 2017.
- AZEVEDO, A. M. M. Análise top-down e bottom-up de um Programa de Inovação Energética: o Programa Nacional de Produção e Uso de Biodiesel (PNPB). **Management and Connections Journal**, 2013. 32-51.
- BENTIVOGLIO, D.; FINCO, A.; BACCHI, M. R. P. Interdependencies between Biofuel, Fuel and Food Prices: The Case of the Brazilian Ethanol Market. **Energies**, p. 464-479, 2016.
- BERGMANN, J. C. et al. Biodiesel production in Brazil and alternative biomass feedstocks. **Renewable and Sustainable Energy Reviews**, Fevereiro 2013. 411-420.
- BHUTTO, A. W. et al. Forecasting the Consumption of Gasoline in Transport Sector in Pakistan Based on ARIMA Model. **Environmental Progress & Sustainable Energy**, p. 1490-1497, 2017.
- BOX, G.; JENKINS, G. **Time Series Analysis, forecast and control**. San Francisco: Holden-Day, 1970.
- BOX, G.; JENKINS, G. **Time Series Analysis, forecast and control**. Revisada. ed. San Francisco: Holden-Day, 1976.

- BOX, G.; JENKINS, G.; REINSEL, G. **Time Series Analysis Forecasting and Control**. 4. ed. Nova York: John Wiley & Sons, 2008.
- BRADSHAW, A. Regulatory change and innovation in Latin America: The case of renewable energy in Brazil. **Utilities Policy**, 2017. 156-164.
- BROSEN, W. **Projections of U.S. Production of Biodiesel Feedstock**. Report prepared for Union of Concerned Scientists and The International Council on Clean Transportation. Washington. 2015.
- BUENO, R. L. S. **Econometria de séries temporais**. São Paulo: Cengage Learning, 2008.
- CARDOSO, B. F.; SHIKIDA, F. A.; FINCO, A. Análise Fatorial do Sistema Agroindustrial do Biodiesel no Brasil e na União Europeia. **RESR**, p. 551-568, 2017b.
- CARDOSO, B. F.; SHIKIDA, P. F. A.; FINCO, A. Development of Brazilian Biodiesel Sector from the Perspective of Stakeholders. **Energies**, 2017a. 1-14.
- CÉSAR, A. S. et al. The potential of waste cooking oil as supply for the Brazilian biodiesel chain. **Renewable and Sustainable Energy Reviews**, 2017. 246-253.
- DICKEY, D. A. Power of Unit Root Tests. **Proceedings of business and economic statistics Sections**, v. 74, p. 427-431, 1984.
- ESTEVEZ, R. A.; PEREIRA, R. G. Análise sobre a Evolução do Biodiesel no Brasil. **Espacios**, 2016. 5-22.
- FREITAS, V. F. et al. Participação da agricultura Familiar no Programa Nacional de Produção e Uso do Biodiesel (PNPB) no período de 2008 a 2015. **RDS**, 2017. 59-80.
- FURLANETTO, E. L.; SANTOS, E. D. Difusão de Inovações Sustentáveis: o caso do biodiesel de mamona no Estado da Paraíba. **Teoria e Prática em Administração**, 2014. 78-103.
- GALVÃO, M. V. et al. O Programa Nacional de Produção e Uso do Biodiesel e a Agricultura Familiar. **Ciência & Tecnologia: Fatec-JB**, 2016. 65-69.
- GRANGER, C. Developments in the study of cointegrated economic variables. **Oxford Bulletin of economics and statistics**, v. 48, p. 213-228, 1986.
- GUJARATI, D. N.; PORTER, D. C. **Econometria Básica**. 5. ed. Porto Alegre: AMGH, 2011.
- GUPTA, A.; VERMA, J. P. Sustainable bio-ethanol production from agro-residues: A review. **Renewable and Sustainable Energy Reviews**, 2015. 550-567.
- HO, D. P.; NGO, H. H.; GUO, W. A mini review on renewable sources for biofuel. **Bioresource Technology**, 11 Julho 2014. 742-749.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. **Forecasting Principles and Practice**. 2. ed. Melbourne: OTexts, 2018.

IPEA. **Instituto de Pesquisa Econômica Aplicada**, 2017. Disponível em: <<http://www.ipeadata.gov.br>>.

JOHNSON, D.; KING, M. **Basic Forecast Techniques**. London: Butterworth & Co., 1988.

KLEWITZ, J.; HANSEN, E. G. Sustainability-oriented innovation of SMEs: a systematic review. **Journal of Cleaner Production**, 2014. 57-75.

KNOTHE, G.; VAN GERPEN, J.; KRAHL, J. **The Biodiesel Handbook**. 2. ed. [S.l.]: Academic Press and AOCS Press, 2010.

KWIATKOWSKI, D. et al. Testing the null hypothesis of stationarity against the alternative of a unit root. **Journal of Econometrics**, v. 54, p. 159-178, 1992.

LINGELBACH, D. et al. The innovation process in emerging economies. **ENTREPRENEURSHIP AND INNOVATION**, 2015. 5-17.

MACKINNON, J. G. Numerical distribution functions for unit root and cointegration tests. **Journal of applied econometrics**, v. 11, p. 601-618, 1996.

MAHMOUD, E. Accuracy in forecasting: A survey. **Journal of Forecast**, p. 139–159, 1984.

MAKRIDAKIS, S.; STEVEN, W.; HYNDMAN, R. **Forecasting: Methods and Applications**. 3. ed. New Jersey: John Wiley & Sons, 1998.

MELIKOGLU, M. Demand forecast for road transportation fuels including gasoline, diesel, LPG, bioethanol and biodiesel for Turkey between 2013 and 2023. **Renewable Energy**, p. 164-171, 2014.

MELO, C. A.; JANNUZZI, G. M.; BAJAY, S. V. Nonconventional renewable energy governance in Brazil: Lessons to learn from the German experience. **Renewable and Sustainable Energy Reviews**, 2016. 222-234.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**. New Jersey: John Wiley & Sons, 2007.

MORENO-PÉREZ, O. M.; MARCOSSI, G. P. C.; ORTIZ-MIRANDA, D. Taking stock of the evolution of the biodiesel industry in Brazil: Business concentration and structural traits. **Energy Policy**, 2017. 525-533.

MORETTIN, P. A. **Econometria Financeira - um curso em séries temporais financeiras**. 1. ed. São Paulo: Blucher, 2008.

MORETTIN, P. A. **Econometria financeira - Um curso em séries temporais financeiras**. 2. ed. São Paulo: Blucher, 2011.

RICO, J. A. P.; SAUER, I. L. A review of Brazilian biodiesel experiences. **Renewable and Sustainable Energy Reviews**, 2015. 513-529.

SALGADO, R. J. S. F. et al. A contribuição do Programa Nacional de Produção e Uso do Biodiesel (PNPB) para estabilização da renda agrícola dos agricultores da Bahia no anos 2005/2014. **Rev. Econ. NE**, 2016. 27-40.

SANTOS, G. R. et al. A AGROINDÚSTRIA CANAVIEIRA E A PRODUÇÃO DE ETANOL NO BRASIL: CARACTERÍSTICAS, POTENCIAIS E PERFIL DA CRISE ATUAL. In: SANTOS, G. R. **Quarenta Anos de Etanol em Larga Escala no Brasil, desafios, crises e perspectivas**. Brasília: Ipea, 2016. p. 17-46.

SANTOS, J. J. et al. Parcerias entre Brasil e Estados Unidos na promoção dos biocombustíveis para o desenvolvimento sustentável. **Espacios Públicos**, 2017. 43-62.

SCHWARZ, G. E. Estimating the dimension of a model. **Annals of Statistics**, v. 6, p. 461-464, 1978.

SENNA, V. A relação dos gastos em programas de assistência social com as variáveis macroeconômicas brasileiras. **Dissertação (Mestrado) - Universidade Federal de Santa Maria**, Santa Maria, 2015.

SILVA, R. C.; MARCHI NETO, I.; SEIFERT, S. S. Electricity supply security and the future role of renewable energy sources in Brazil. **Renewable and Sustainable Energy Reviews**, 2016. 328-341.

SOUZA, A. M. et al. Electrical energy supply for Rio Grande do Sul, Brazil, using forecast combination of weighted eigenvalues. **GEPROS: Gestão da Produção, Operações e Sistemas**, v. 6, p. 23, 2011.

SOUZA, F. M. **Modelos de Previsão: aplicações à energia elétrica - ARIMA - ARCH - AI e ACP**. Curitiba: Appris, 2016.

SOUZA, V. H. A. et al. ANÁLISE DO PROGRAMA NACIONAL DE PRODUÇÃO E USO DO BIODIESEL (PNPB): RESULTADOS E CRÍTICAS. **Revista de Administração Geral**, 2015. 23-41.

WERNER, L. Um modelo composto para realizar previsão de demanda através da integração da combinação de previsões e do ajuste baseado na opinião. **Tese (Doutorado) - Universidade Federal do Rio Grande do Sul**, Porto Alegre, 2005.

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

WERON, R. Electricity price forecasting: A review of the state-of-the-art with a look into the future. **International Journal of Forecast**, v. 30, p. 1030–1081, 2014.