

**Universidade de São Paulo
Escola Superior de Agricultura “Luiz de Queiroz”**

**Ensaio sobre a situação econômica da indústria sucroenergética e o
consumo de combustíveis leves no Brasil**

Lucas Rodrigues

Dissertação apresentada para obtenção do título de Mestre
em Ciências. Área de concentração: Economia Aplicada.

**Piracicaba
2021**

Lucas Rodrigues
Bacharel em Administração

Ensaio sobre a situação econômica da indústria sucroenergética e o consumo de combustíveis leves no Brasil

versão revisada de acordo com a resolução CoPGr 6018 de 2011

Orientador:
Prof. Dr. **LUCIANO RODRIGUES**

Dissertação apresentada para obtenção do título de Mestre Ciências. Área de concentração: Economia Aplicada.

Piracicaba
2021

**Dados Internacionais de Catalogação na Publicação
DIVISÃO DE BIBLIOTECA – DIBD/ESALQ/USP**

Rodrigues, Lucas

Ensaio sobre a situação econômica da indústria sucroenergética e o consumo de combustíveis leves no Brasil / Lucas Rodrigues. - - versão revisada de acordo com a resolução CoPGr 6018 de 2011. Piracicaba, 2021.

129 p.

Dissertação (Mestrado) - - USP / Escola Superior de Agricultura “Luiz de Queiroz”.

1. Açúcar 2. Etanol 3. Performance financeira 4. Métodos de previsão 5. Algoritmos de classificação I. Título

SUMÁRIO

RESUMO	5
ABSTRACT	6
1. INTRODUÇÃO.....	7
2. POLÍTICAS PÚBLICAS, CONDIÇÕES DE MERCADO E A PERFORMANCE FINANCEIRA DA INDÚSTRIA SUCROENERGÉTICA NO BRASIL DE 2001 A 2019	9
2.1. INTRODUÇÃO	9
2.2. METODOLOGIA.....	12
2.2.1. Estratégia analítica e procedimento estatístico	12
2.2.2. Análise de Cluster.....	14
2.2.3. Métodos de Classificação	15
2.2.4. Discriminante Canônico de Fisher	16
2.2.5. Análise de Discriminante Quadrática	16
2.2.6. Random Forest.....	17
2.2.7. SVM	18
2.2.8. Seleção do Método de Classificação	19
2.2.9. Base de dados	20
2.3. ANÁLISE E DISCUSSÃO DOS RESULTADOS	21
2.3.1. Análise de Cluster para a safra 2009/2010	21
2.3.2. Classificação com SVM e evolução da situação econômico-financeira do setor sucroenergético brasileiro.....	24
2.4. CONSIDERAÇÕES FINAIS.....	33
REFERÊNCIAS	36
3. MÉTODOS DE PREVISÃO APLICADOS AO CONSUMO BRASILEIRO DE COMBUSTÍVEIS LEVES	43
Resumo	43
Abstract.....	43
3.1. INTRODUÇÃO	43
3.2. O MERCADO DE COMBUSTÍVEIS BRASILEIRO	45
3.3. MÉTODOS DE PREVISÃO UTILIZADOS NO ESTUDO.....	48
3.3.1. Fonte de dados e pré-tratamento.....	49
3.3.2. Determinação de hiperparâmetros dos modelos.....	50
3.3.3. Modelo Sazonal Autoregressivo Integrado com Médias Móveis (Sarima).....	52

3.3.4. Vetor Autoregressivo com Mecanismo de Correção de Erro (VECM)	55
3.3.5. Modelos Lineares Dinâmicos (Modelo Estrutural).....	58
3.3.6. Modelo de Decomposição de Séries Temporais por Regressão Local (STL)	60
3.3.7. Redes Neurais Artificiais (ANN).....	62
3.3.8. Máquinas de Vetores de Suporte (SVM)	63
3.3.9. Sistema Neuro-Fuzzy Híbrido (HyFIS)	65
3.3.10. Random Forest	66
3.3.11. Grey Models.....	68
3.3.12. Modelos Híbridos.....	69
3.3.13. Modelos de aprendizagem conjunta (Ensemble Learning).....	70
3.3.14. Métricas de avaliação e testes estatísticos para comparação de algoritmos	72
3.4. RESULTADOS E DISCUSSÃO.....	73
3.4.1. Resultados da validação cruzada.....	73
3.4.2. Resultados dos erros de previsão e comparação dos modelos	75
3.4.3. Resultados dos Modelos de Aprendizagem Conjunta.....	81
3.5. CONCLUSÕES.....	86
REFERÊNCIAS.....	88
4. CONCLUSÕES	95
REFERÊNCIAS.....	97
APÊNDICES.....	99

RESUMO

Ensaio sobre a situação econômica da indústria sucroenergética e o consumo de combustíveis leves no Brasil

A importância do setor sucroenergético brasileiro remete a uma série de aspectos, tais como, ambientais pelo fornecimento de energia renovável, econômicos pela geração de emprego e renda e de segurança de abastecimento energético pelo fornecimento de combustíveis e de energia elétrica. Tendo isso em vista, este trabalho tem por objetivo auxiliar a tomada de decisão dos agentes públicos e privados relacionados a esse setor pela apresentação de dois artigos. O primeiro busca analisar por meio de diferentes técnicas estatísticas o passado recente do setor avaliando como as mudanças nas condições de mercado, produtivas e de políticas públicas afetaram a saúde financeira das empresas atuantes nessa indústria. Os resultados evidenciam uma elevada heterogeneidade na saúde financeira das unidades produtoras em atividade, com mais de um terço das empresas em situação crítica na safra 2018/2019. Essas informações são relevantes para instituições financeiras e investidores que desejam aportar recursos nessas companhias, como também para o governo e os próprios gestores atuantes no setor por poder vislumbrar como deverá ser a perspectiva de crescimento dessas empresas nos próximos anos. O segundo artigo avalia a acurácia de diferentes métodos na previsão do consumo de combustíveis leves no Brasil. Os resultados obtidos indicam que é possível realizar previsões no horizonte de até 12 meses com um erro inferior a 3%, além de evidenciar o benefício da utilização de métodos mais complexos frente a um método ingênuo de previsão. Os resultados são relevantes do ponto de vista técnico, fornecendo indicações sobre os melhores métodos de previsão, além de servir como ferramental para um melhor planejamento tendo em vista que o bom dimensionamento da demanda futura garante que os recursos sejam alocados de maneira mais eficiente para garantir abastecimento energético.

Palavras-chave: Combustíveis, SVM, Séries temporais, Análise de Cluster, Previsão, Sucroenergético, Indicadores financeiros

ABSTRACT

Essays on the economic situation of the sugarcane industry and the consumption of light fuels in Brazil

Brazilian sugarcane industry has important contributions in a several different aspects, such as enviromental because of the renewable energy supply, economical due to job and wealth generation and energy supply securitiy due to the supply of fuels and eletric energy. For these reasons, this work aims to assist the decision making of public and private agents related to this industry by the elaboration of two articles. The first one is intent to characterize the evolution of the economic-financial situation of the sugarcane energy industry over the recent past using statistical technics in order to related this evolution with market, productive and public policy conditions. The results reveal that the current financial condition of sugarcane industry is quite heterogeneous, with more than a third of the companies in a critical situation in the 2018/2019 harvest. This information are relevant for investors and financial institutions with an interest in contributing funds to this industry, as for the government and the managers of plants in operation for planning how it should be the growth perspective for this companies in the following years. The second article evaluates the accuracy of several methods whose objective is to forecast brazilian light fuel consumption. The results obtained indicate that it is possible to make predictions in the horizon of up to 12 months with an error of less than 3%, in addition to evidencing the benefit of using more complex methods compared to a naive forecasting method. The results are important in a technical point of view, since it guides to a improvement on the choice of the best forecasting method, but also in a planning context, once that a good demand forecast guarantee most efficiency on resources employed in order to ensure the energy supply.

Keywords: Fuel, SVM, Time Series, Cluster Analysis, Forecast, Sugarcane industry, Financial Indicators

1. INTRODUÇÃO

O setor sucroenergético brasileiro possui destaque tanto em âmbito nacional quanto internacional. Trata-se de uma indústria importante na geração de riqueza e com dinâmica peculiar ao longo de sua história.

Como qualquer setor do agronegócio, o setor produtivo da cana-de-açúcar apresenta intensa influência das condições climáticas para o resultado da lavoura. A produção de açúcar, por sua vez, remete ao mercado de *commodities*, cuja formação de preços se dá pelo balanço internacional de oferta e demanda, sujeitando o adoçante a ciclos de preços e dependência de variáveis como câmbio e políticas externas, incluindo subsídios à produção e acordos internacionais, por exemplo.

Como produtor de etanol, a indústria sucroenergética também depende dos preços dos combustíveis fósseis e do balanço de oferta e demanda por petróleo. Além disso, nos últimos anos, o forte apelo por políticas ambientais que favoreçam a descarbonização das matrizes energéticas tem alterado a dinâmica do mercado de biocombustíveis por meio de políticas específicas ao setor.

Em meio a essa estrutura complexa, um terceiro produto se consolidou na indústria canavieira. A bioeletricidade surgiu como um nova fonte energética renovável e, em 2017, foi responsável por evitar a emissão de 7,5 milhões de toneladas de gases de efeito estufa (toneladas de carbono equivalente ou CO_{2eq}), mesmo com potencial técnico apresentando ociosidade de 85% (FARINA; SOUZA, 2018).

Por fim, tem-se a produção desses produtos a partir do uso de uma única matéria-prima: a cana-de-açúcar. Assim, a decisão sobre a proporção de cana-de-açúcar direcionada à fabricação de etanol ou açúcar depende da estratégia de cada empresa, de modo a considerar os custos e rentabilidades dos diferentes produtos. O *mix* de produção é resultado da interação e equilíbrio dos mercados de açúcar e etanol, como também de outras *commodities* agrícola e, ainda, da situação no mercado de petróleo devido a concorrência direta do biocombustível com a gasolina.

Portanto, a alta complexidade produtiva, mercadológica e, ainda, as diferentes medidas de políticas públicas relacionadas à essa indústria contribuem para a sua dinâmica bastante peculiar. Entender o comportamento das empresas e dos mercados frente a essas variáveis é uma forma de compreender o histórico deste setor e de lançar luz sobre o futuro da indústria.

Nesse contexto, são inúmeros os aspectos que ainda merecem maior atenção da literatura acadêmica, com a necessidade de identificação, análise e mensuração de problemas que vão desde elementos relacionados ao sistema de produção, passando pelo funcionamento e estruturação dos mercados em que a indústria atua e, ainda, pela avaliação de impacto e efetividade de políticas públicas.

Isso posto, o presente estudo, composto por dois artigos, explora aspectos relacionados à indústria sucroenergética que ainda não foram plenamente avaliados pela literatura disponível.

O primeiro artigo analisa a evolução da performance econômico-financeira das empresas do setor sucroenergético entre as safras 2001/2002 e 2018/2019. Para tanto, utiliza dados primários coletados de demonstrativos financeiros, análise de agrupamentos e algoritmos de classificação que permitem agregar as companhias em grupos representativos ao longo das safras. Essa lógica oferece elementos para avaliar a situação econômica das empresas e entender como a condição da indústria se alterou ao longo do tempo frente às mudanças no sistema de produção, nas condições de mercado e no arcabouço regulatório vigente.

O segundo artigo, por sua vez, propõe-se a avaliar aspectos relacionados a demanda por combustíveis leves, que possui relação direta com o etanol produzido por essa indústria. O objetivo do trabalho compreende a avaliação da acurácia de diversos métodos de previsão no dimensionamento do consumo de combustíveis leves no país (gasolina pura, etanol anidro, etanol hidratado e GNV). Os resultados do estudo oferecem elementos para aperfeiçoamento do planejamento dos agentes públicos e privados que atuam no mercado brasileiro de combustíveis. A melhor projeção da demanda por combustíveis no país também é importante para as empresas produtoras de etanol, trazendo elementos para a definição das estratégias comerciais e produtivas no curto prazo, bem como para referenciar a participação do etanol na matriz energética nacional no médio e longo prazos.

De forma conjunta, os estudos fornecem fundamentos para a discussão do futuro da matriz energética de transportes do Brasil. Do lado da oferta, analisa a condição financeira da indústria produtora de etanol e como seu estado atual deve impactar a expansão da produção no curto e médio prazo. Do lado da demanda, avalia a possibilidade do uso de um ferramental importante para o planejamento do abastecimento e dimensionamento da demanda por transportes.

Ambas as contribuições são importantes para a recém criada Política Nacional de Biocombustíveis do Brasil, ou RenovaBio, estabelecida pela Lei nº 13.576 de dezembro de 2017, que visa uma reestruturação da matriz energética de combustíveis brasileira a fim de aumentar a participação dos biocombustíveis e reduzir a intensidade de carbono da matriz brasileira de transportes.

2. POLÍTICAS PÚBLICAS, CONDIÇÕES DE MERCADO E A PERFORMANCE FINANCEIRA DA INDÚSTRIA SUCROENERGÉTICA NO BRASIL DE 2001 A 2019

Resumo

Nos últimos anos, o mercado brasileiro de combustíveis leves no Brasil vivenciou momentos de mudanças intensas. Nesse período, a indústria sucroalcooleira brasileira experimentou um crescimento intenso, sucedido de uma das maiores crises de sua história no período de 2008 até 2014. Nesse contexto, este estudo tem por objetivo avaliar a evolução da situação econômico-financeira do setor sucroenergético no Brasil. A metodologia se apoia em técnicas de Análise de *Cluster* e classificação por meio de SVM para a avaliação multidimensional dos indicadores financeiros das empresas e identificação de grupos representativos do setor. Os resultados evidenciam que a performance financeira das companhias acompanhou as condições de mercado, as mudanças tecnológicas e, mais importante, as alterações de políticas públicas associadas ao mercado de etanol. Atualmente existe uma elevada heterogeneidade da saúde financeira das empresas, com mais de um terço das companhias em situação crítica e com baixa possibilidade de crescimento no curto prazo. As informações obtidas oferecem indicações importantes para a orientação dos agentes públicos e privados que atuam nesse setor, incluindo fundamentos para a regulação da recém-criada Política Nacional de Biocombustíveis no Brasil (RenovaBio).

Palavras-Chave: Cana-de-Açúcar; Máquina de Vetor de Suporte; Análise de *Cluster*; Etanol; Performance Financeira

Abstract

In recent years, the light fuel market in Brazil experienced moments of intense change. During this period, the Brazilian sugarcane energy industry grew at high rates, but it was followed by one of the biggest crises in its history. This study is intended to evaluate the evolution of the economic-financial situation of the sugarcane energy industry in Brazil. A Cluster Analysis e a SVM classification was carried out to make a multidimensional evaluation of firms' financial indexes and identify representative groups in the industry. The results showed that companies' financial performance was in line with the conditions prevailing in the market, technological shifts e, more importantly, changes in public policies associated with the ethanol market. Besides, there is a high heterogeneity in the financial health of companies. More than a third of these ones was in a critical situation in the 2019/2020 harvest season and are not able to substantially increase their production in the short term. The information obtained provides important elements for guiding the decisions of public and private agents operating in this sector, including fundamentals for regulating the newly created National Biofuel Policy (RenovaBio) in Brazil.

Keywords: Sugarcane; Support Vector Machine; Cluster Analysis; Ethanol; Financial Performance

2.1. INTRODUÇÃO

No contexto doméstico, o setor sucroenergético é notadamente um dos mais importantes do agronegócio brasileiro. A indústria cana-de-açúcar envolve 386 unidades produtoras, cerca

de 70 mil produtores rurais e 747 mil empregos diretos (MAPA, 2020; MTPS, 2020), além de apresentar um produto interno bruto (PIB) superior a US\$ 40 bilhões (Neves e Trombim, 2014).

Adicionalmente, o setor é responsável por cerca de 18% de toda a energia primária consumida no país (EPE, 2020a) com a produção de etanol e de energia elétrica gerada a partir do bagaço e da palha da cana-de-açúcar, a chamada bioeletricidade.

No mercado externo, o Brasil também se consolidou entre os maiores produtores e exportadores de açúcar, com participação próxima a 50% do volume comercializado mundialmente na safra 2020/2021 (USDA, 2020).

Além desse protagonismo na economia doméstica e no mercado internacional, nos últimos anos essa indústria se destacou pela dinâmica atípica vivenciada por toda a cadeia produtiva. Após a conclusão da desregulamentação, que garantiu a liberação dos preços e o fim das quotas de produção, o setor sucroenergético apresentou crescimento surpreendente entre o início dos anos 2000 e 2008.

Nesse período, a moagem de cana-de-açúcar no país cresceu cerca de 101% (MAPA, 2020), estimulada pela introdução dos veículos *flex*¹ no mercado brasileiro, pela perspectiva de aumento no preço mundial do petróleo e pela orientação do poder público, que estabeleceu diversas medidas para a maior competitividade do etanol, incluindo a diferenciação tributária do biocombustível em relação à gasolina, o menor imposto sobre os veículos flexíveis e a disponibilidade de recursos do BNDES² para a ampliação da produção nacional.

Essa tendência de crescimento intenso mudou de forma expressiva a partir da crise financeira mundial em 2008. Além da elevação do custo do crédito em um momento de elevada alavancagem financeira das empresas, o governo brasileiro passou a adotar uma política de contenção dos preços da gasolina como medida de controle inflacionário, com a redução de tributos sobre o derivado e o controle dos valores praticados pela Petrobrás³ domesticamente.

Esse movimento eliminou as margens do setor produtivo e estabeleceu uma crise sem precedentes na indústria sucroenergética, com a estagnação da produção, o fechamento de mais de 100 plantas produtivas e a perda de milhares de empregos (Bressan Filho, 2009; Moraes e Bacchi, 2014; Moraes *et al.*, 2014; Ramos, 2016; EPE, 2020b).

¹ Os veículos *flex* podem ser abastecidos com etanol hidratado, com gasolina ou qualquer mistura desses dois combustíveis. No Brasil, os proprietários de veículos *flex* optam pelo combustível desejado a cada abastecimento em função do preço relativo dos produtos e de suas preferências.

² O Banco Nacional de Desenvolvimento Econômico e Social é uma empresa pública federal com objetivo de direcionar financiamentos de longo prazo e investimentos em segmentos estratégicos da economia brasileira.

³ A Petróleo Brasileiro S.A (Petrobrás) é uma empresa brasileira de capital misto cujo acionista majoritário é o governo federal. A empresa detém cerca de 95% do mercado de refino no país, em uma estrutura de quase monopólio.

Com o término das eleições presidenciais em 2014, um novo ciclo de mudança no arcabouço institucional foi observado. A partir desse momento, a diretriz visando o controle inflacionário deu lugar à preocupação com o déficit público, que havia saltado de R\$ 44,3 bilhões (1,53% do PIB) em 2008 para R\$ 343,9 bilhões (6,70% do PIB) em 2014 (BACEN, 2020). Como consequência, o governo brasileiro elevou as alíquotas de tributos federais sobre a gasolina e o etanol em níveis superiores aqueles observados antes do controle de preço.

Mais recentemente, a partir de 2016, o mercado brasileiro presenciou uma nova redefinição da política de precificação da gasolina comercializada pela Petrobrás, a qual passou a praticar reajustes periódicos de preços alinhados com as variações na cotação internacional do petróleo e na taxa de câmbio.

Todas essas transformações tecnológicas, comerciais e, principalmente, institucionais e de política pública impactaram severamente e de maneira distinta a condição financeira das empresas produtoras do setor sucroenergético (usinas e destilarias).

Nesse contexto, esse estudo tem a intenção de caracterizar a evolução da situação econômico-financeira da indústria sucroenergética brasileira nos últimos 18 anos. Se busca estabelecer uma relação entre essa evolução e as transformações observadas nos mercados de açúcar e de etanol, com destaque para as inúmeras mudanças nas diretrizes de políticas públicas delineadas pelo governo federal para o setor de combustíveis nos países.

Além da importância do tema, o estudo se justifica pela ausência de trabalhos que exploraram a problemática de forma apropriada. A literatura disponível que se dispôs a avaliar essa dinâmica é baseada em avaliações pontuais, em estudos de caso ou em metodologias pouco fundamentadas conduzidas por consultorias e agentes privados, por exemplo, Noriller *et al.* (2011), Nascimento (2014), Martins *et al.*, (2015), Nastari (2014) e Guedes *et al.*, (2016).

O trabalho conduzido por Rodrigues e Rodrigues (2018), por sua vez, apesar de ter empregado um ferramental analítico similar ao utilizado neste estudo, apresenta como restrição o reduzido horizonte temporal de análise. Os autores avaliaram informações de dois anos, permitindo apenas uma avaliação pontual da situação da indústria naquele momento.

O presente trabalho supera essa limitação ao utilizar uma base de dados única composta por 1.387 demonstrativos financeiros publicados entre as safras 2001/2002 e 2018/2019. Adicionalmente, neste estudo diferentes métodos de classificação das empresas foram testados, tornando o procedimento metodológico mais robusto. Com isso, o trabalho oferece informações inéditas sobre a evolução da condição financeira da indústria sucroenergética no Brasil ao longo dos últimos 18 anos. Os resultados são particularmente importantes para investidores e

instituições financeiras, uma vez que revela parâmetros para uma avaliação objetiva das empresas e sugere qual a migração mais provável entre os grupos representativos da indústria.

O entedimento dessa relação e a caracterização da heterogeneidade econômico-financeiro das empresas produtoras é relevante por oferecer fundamentos à regulação da recém-criada Política Nacional de Biocombustíveis no Brasil. A referida política, conhecida como RenovaBio, foi estabelecida pela Lei nº 13.576 de dezembro de 2017 e entrou em vigor a partir do final de 2019.

O Programa define metas decenais de descarbonização para o setor de transporte a partir da ampliação da participação dos biocombustíveis na matriz energética nacional. Trata-se, portanto, de uma iniciativa alinhada com o compromisso de redução de emissões de gases de efeito estufa firmado pelo Brasil no Acordo de Paris e com a necessidade de redução de importações de combustíveis para atendimento do mercado doméstico. Para 2030, as metas já estabelecidas preveem a necessidade de expansão da produção de etanol dos atuais 30 bilhões de litros para 50 bilhões de litros (CRBIO, 2020; CNPE, 2020).

Diante dessa perspectiva de crescimento da oferta do biocombustível, a análise proposta também deve trazer elementos importantes à tomada de decisão dos agentes que operam nesse setor, incluindo os atuais gestores das unidades em operação, os investidores com interesse em aportar recursos nessa indústria e as principais instituições financeiras do país.

Assim, os resultados devem permitir reflexões para questionamentos atuais no país. Como as políticas públicas favoreceram ou prejudicaram a condição financeira das empresas nos últimos anos? A situação atual do setor sugere a possibilidade de um novo ciclo de crescimento da produção? Qual o papel do setor público para que isso ocorra?

Para atingir o objetivo proposto, esse estudo utiliza técnicas para classificação das companhias em grupos homogêneos e acompanhamento da sua evolução, permitindo uma análise lógica e sequencial da situação financeira da indústria vis-à-vis as mudanças tecnológicas, de mercado e de políticas públicas observadas no período.

2.2. METODOLOGIA

2.2.1. Estratégia analítica e procedimento estatístico

A avaliação proposta foi inicialmente conduzida a partir da abordagem baseada em indicadores financeiros, conhecida na literatura por FRA (*Financial Ratio Analysis*). Trata-se de uma estrutura analítica consolidada nos meios acadêmico e privado, com início datado no fim do século IXX (Horrigan, 1968).

Essa técnica tem sido utilizada para identificar as áreas que demandam maior avaliação e cuidado no dimensionamento estratégico da corporação, comparar firmas distintas ou períodos diferenciados de uma mesma empresa, indicar as tendências do negócio e formular modelos quantitativos mais complexos (Elliott e Elliott, 2011; Fridson e Alvarez, 2002; Wild e Subramanyam, 2008; Barnes, 1987; Healy e Palepu, 2012).

De acordo com Bodie, Kane e Marcus (2015), uma avaliação adequada do desempenho das empresas deve, por um lado, considerar a firma pela ótica dos ativos, mensurando a eficiência dos seus investimentos, a rentabilidade e a lucratividade; e, por outro lado, pelos passivos, avaliando a prudência em suas decisões de financiamento, por meio da sua capacidade de solvência (liquidez) e do nível de alavancagem (endividamento e cobertura de caixa). Assim, conforme destacam Higgins (2014) e Fridson e Alvarez (2002), a aplicação correta da FRA deve incluir uma visão sistêmica de diversos indicadores financeiros, na medida em que estes possuem influência mútua entre si.

Nesse contexto, é comum o emprego da FRA associada a técnicas de estatística multivariada para permitir uma avaliação multidimensional da situação econômico-financeira e reduzir a influência da percepção subjetiva do pesquisador na avaliação do problema (Fridson e Alvarez, 2002; Barnes, 1987; Altman, 1968).

A integração da FRA com técnicas de análise multivariadas é comum na literatura sobre o tema e se dá, por exemplo, pela aplicação de análise fatorial para agrupamento de indicadores financeiros como variáveis explicativas do desempenho operacional de empresas (Laurent, 1979; Carvalho e Bialoskorko, 2007; Campos, 2014), análise de discriminante (Altman, 1968; Taffler, 1982; Edmister, 1972; Zuge e Neto, 2011; Altman *et al.*, 1994), árvores de decisão e *Random Forests* (Liu *et al.*, 2015; Frydman *et al.*, 1985), máquina de vetor de suporte (SVM) (Zhang *et al.*, 2015; Xie *et al.*, 2011; Hsu e Hung, 2009), e análise de agrupamentos (Capece *et al.*, 2010; Sook Lu, 2012; Gupta e Huefner, 1972; Salmi *et al.*, 1986; Boillat *et al.*, 2002; Corrar e Pohlmann, 2004; Callado *et al.*, 2015; Angelo e Sanvicente, 1992).

No presente estudo, visando classificar as empresas em classes representativas e avaliar a evolução desses grupos ao longo do tempo, foi utilizada a técnica de análise de agrupamentos (ou análise de *cluster*) e os algoritmos *Random Forest*, Análise de Discriminante e Máquina de Vetor de Suporte (SVM).

A estratégia adotada utiliza indicadores calculados a partir dos demonstrativos financeiros que retratam a condição das empresas em termos de liquidez, lucratividade e endividamento. Os índices financeiros tomados inicialmente foram: liquidez corrente (LC), liquidez geral (LG), margem EBIT (ME), margem EBITDA (MEA), margem bruta (MB),

margem líquida (ML), retorno sobre ativos (ROA), endividamento geral (EG), endividamento oneroso (EO, ou dívida onerosa sobre receita) e despesa financeira por faturamento (DF.F). Para a definição desses indicadores, foram selecionados os índices mais recorrentes na literatura sobre o tema.

2.2.2. Análise de *Cluster*

A análise de *cluster* foi inicialmente empregada para identificar o número e a estrutura dos grupos de empresas que caracterizam a condição econômico-financeiras desta indústria na safra 2009/2010. Esse tipo de técnica permite a agregação de um conjunto de objetos segundo um vetor de características, seguindo um critério formal e menos sensível à vieses do pesquisador ou analista (Everitt *et al.*, 2011).

A escolha do ciclo agrícola 2009/2010 se deve à sua maior variabilidade amostral durante o período de análise (Tabela 1). A identificação do número ideal de grupos representativos da condição financeira da indústria sucroenergética foi baseada na inspeção visual do dendograma (Figura 1) e em diferentes índices de qualidade do processo de agrupamento (Tabela 2). Em linhas gerais, esses índices se fundamentam em métricas estatísticas de dispersão, como variância e desvio-padrão, ou matemáticas, como medidas de distância, calculadas entre *clusters* e dentro dos mesmos a fim de mensurar o grau de dissimilaridade e/ou similaridade dos grupos em cada etapa do processo. Para maior detalhamento ver Everitt *et al.*, (2011), Desgraupes (2018) e Milligan e Cooper (1985).

Para a implementação da análise de *cluster*, uma avaliação da correlação entre os indicadores foi realizada eliminando os índices cuja correlação excedia o valor de 0,7. Conforme sugerido por Everitt *et al.*, (2011), esse procedimento é indicado para manter a ponderação homogênea entre os atributos utilizados na análise.

O dendograma foi construído a partir dos indicadores padronizados, tendo como referência o método de *cluster* hierárquico, a medida de dissimilaridade definida pela distância Euclidiana (Eq. 1) e o procedimento aglomerativo proposto por Ward (Ward, 1963). O método de Ward é baseado na ideia de que os grupos quando distribuídos em um plano multivariado determinado pela matriz de características terão o comportamento de uma elipse em relação ao vetor de média das características. Ainda, outros métodos foram testados⁴ e a técnica de Ward foi a que gerou os resultados com maior sentido do ponto de vista econômico-financeiro.

⁴ Os métodos hierárquicos testados foram: ligação única, ligação completa, método do centróide, método da média e mediana. O método não hierárquico conhecido como *k*-médias também foi avaliado.

$$d(x_1, x_2) = \sqrt{\sum_{i=1}^m (x_{1i} - x_{2i})^2} \quad (1)$$

Em que x_1 e x_2 são elementos da amostra (grupos de usinas) descritos por m características (indicadores financeiros, nesse caso).

O método de Ward é um algoritmo iterativo que unifica, em cada etapa de sua execução, um par de grupos selecionados. Sendo x_{ijk} o indicador financeiro j para um membro i de um grupo k . n_K é o número de membros do k -ésimo *cluster*, \bar{x}_{pk} é a média aritmética do k -ésimo *cluster* para o p -ésimo indicador financeiro e K é o total de grupos em uma interação específica do algoritmo, o critério para escolha dos *clusters* que serão unidos consiste na minimização da variância dentro dos grupos (Eq. 2).

$$ESS = \sum_{k=1}^g \sum_{j=1}^p \sum_{i=1}^{n_k} (x_{ijk} - \bar{x}_{pk})^2 \quad (2)$$

O método da mínima variância de Ward foi implementado utilizando a fórmula recursiva de Lance-Williams (Lance e Williams, 1967). Essa é uma forma flexível capaz de reproduzir a maioria dos algoritmos de *cluster* hierárquicos apenas mudando alguns de seus parâmetros (Everitt *et al.*, 2011).

2.2.3. Métodos de Classificação

Os grupos definidos para a safra 2009/2010 foram adotados como padrão para a classificação dos outros anos da amostra. Assim, é possível avaliar a evolução do desempenho econômico-financeiro da indústria sucroenergética analisando a composição desses grupos e, ainda, a variação das características dos mesmos ao longo do tempo.

As variáveis de entrada selecionadas para o modelo de discriminação dos grupos foram: liquidez corrente, endividamento geral, liquidez geral, despesa financeira por faturamento e retorno sobre ativo. O critério de seleção de variáveis utilizado foi o método progressivo ou *stepwise forward method* (KLECKA, 1980). Como regra classificatória, foram avaliados quatro métodos distintos: Discriminante Canônico de Fisher, Discriminante Quadrático, *Random Forest* e SVM.

O problema abordado por estas técnicas consiste em estimar uma regra ótima de classificação para as empresas dado um conjunto de dados de treinamento $\Omega = \{\mathbf{x}_i, y_i\}_{i=1}^N$, em que \mathbf{x}_i representa o vetor de entrada ou características (indicadores financeiros das companhias) e y_i representa a classe observada (grupos identificados na safra 2009/2010).

2.2.4. Discriminante Canônico de Fisher

O Discriminante Canônico de Fisher ou Análise de Discriminante Linear de Posto Reduzido (*Reduced-Rank Linear Discriminant Analysis - RLDA*) (Fisher,1936) tem por objetivo estimar uma regra matemática para definição da classe a qual uma observação pertence. Esse método utiliza uma combinação linear do vetor de entrada para produzir um hiperplano linear de separação dos grupos da amostra.

O escore de discriminação de uma empresa j é dado por $Y_j = \mathbf{w}^T \mathbf{x}_j$, em que \mathbf{w} é o vetor de coeficientes e \mathbf{x}_j o vetor de entrada. Logo, a variância do escore entre e dentro dos grupos é dada pelas Eqs. (3) e (4).

$$\mathbf{w}^T \mathbf{B}_\mu \mathbf{w} = \mathbf{w}^T \left[\sum_{k=1}^K (\boldsymbol{\mu}_k - \bar{\boldsymbol{\mu}})(\boldsymbol{\mu}_k - \bar{\boldsymbol{\mu}})^T \right] \mathbf{w} \quad (3)$$

$$\text{VAR}(Y) = \sigma_Y = \mathbf{w}^T \mathbf{S} \mathbf{w} \quad (4)$$

Em que $\boldsymbol{\mu}_k$ representa o vetor de médias de um grupo $k = \{1, \dots, K\}$, ou o vetor de medias de $\mathbf{x}_i \forall i \in k$, e $\bar{\boldsymbol{\mu}}$ é o vetor de médias de $\boldsymbol{\mu}_k$, ou o vetor de médias incondicional de \mathbf{x}_i . A matriz \mathbf{S} é a matriz de covariância única assumida como equivalente para todos os grupos.

Os coeficientes lineares são calculados maximizando a razão entre a variância entre *clusters* (Eq. 2) e a variância dentro dos *clusters* (Eq. 3). A classificação final é obtida a partir da distância entre o escore discriminante da observação e o escore médio de um grupo, de modo que a empresa j pertence a um grupo k se a distância Euclidiana é mínima entre o escore da firma e do grupo.

2.2.5. Análise de Discriminante Quadrática

A Análise de Discriminante Quadrática (QDA) consiste em um procedimento bayesiano capaz de reconhecer padrões não-lineares partindo do princípio da desigualdade da matriz de covariância dos grupos da amostra (Johnson e Wichern, 2007).

O objetivo do método compreende minimizar o Custo Esperado de Classificação Incorreta (*Expected Cost of Misclassification – ECM*) assumindo que os grupos são normalmente distribuídos com vetor de médias $\boldsymbol{\mu}_k$ e matriz de covariância \mathbf{S}_k . O custo de classificação incorreta de um elemento para um grupo k_1 dado que esse pertence a k_2 ($c[k_1|k_2]: k_1 \neq k_2 \wedge k_1, k_2 \in \{1, \dots, K\}$) é assumido como equivalente para todos os grupos e

representado por c . O custo da classificação correta ($c[k_1|k_1]$) é zero. Portanto, o ECM da classificação da firma j em um grupo k^* é dado pela Eq. (5).

$$ECM = \sum_{\substack{k=1 \\ k \neq k^*}}^K p_k f_k(\mathbf{x}_j) c[k^*|k] = \sum_{\substack{k=1 \\ k \neq k^*}}^K p_k f_k(\mathbf{x}_j) c \quad (5)$$

Em que $f_k(\mathbf{x}_j)$ é uma distribuição normal multivariada com vetor de média $\boldsymbol{\mu}_k$ e matriz de covariância \mathbf{S}_k , e p_k é a probabilidade *a priori* de um elemento pertencer a uma classe k .

Se todos os custos de classificação incorreta são equivalentes, então o ECM é minimizado pela seguinte regra de classificação: \mathbf{x}_j pertence a k^* se $p_{k^*} f_{k^*}(\mathbf{x}_j) = \max[p_1 f_1(\mathbf{x}_j), \dots, p_K f_K(\mathbf{x}_j)]$ ou, aplicando uma transformação monotônica, $\ln p_{k^*} f_{k^*}(\mathbf{x}_j) = \max[\ln p_1 f_1(\mathbf{x}_j), \dots, \ln p_K f_K(\mathbf{x}_j)]$. Esse critério é equivalente a selecionar o *cluster* que maximiza a probabilidade *a posteriori* de \mathbf{x}_j ser seu membro (Johnson e Wichern, 2007). Finalmente, o escore de discriminação quadrático, assim como a regra de classificação para novas observações para o k -ésimo grupo é definido pela Eq. (6).

$$Q_k(\mathbf{x}_j) = \ln p_k f_k(\mathbf{x}_j) = -\frac{1}{2} \ln |\mathbf{S}_k| - \frac{1}{2} (\mathbf{x}_j - \boldsymbol{\mu}_k)^T \mathbf{S}_k^{-1} (\mathbf{x}_j - \boldsymbol{\mu}_k) + \ln p_k, \quad (6)$$

$$k = 1, \dots, g$$

O escore depende da amplitude da variância do grupo, da probabilidade *a priori* e da distância de mahalanobis entre \mathbf{x}_j e o vetor de médias do *cluster*.

2.2.6. Random Forest

Random Forest é um método de aprendizagem conjunta que gera uma série de árvores de decisão, por meio do clássico algoritmo de Árvores de Classificação e Regressão (*Classification e Regression Trees* - CART) (Breiman, 2001). O princípio do CART é construir uma árvore de decisão realizando partições binárias nos dados com objetivo de otimizar uma medida de “impureza”, que representa o erro de uma classificação incorreta.

Em cada interação do algoritmo essa medida de impureza, ou erro, é utilizada como critério para escolha de uma das variáveis de entrada do modelo para se executar uma quebra em seu domínio, gerando dois conjuntos. Essa medida também define qual o ponto ótimo de partição. Neste estudo, o índice de Gini foi utilizado (Breiman, 1984). Cada divisão gera dois novos subespaços de variáveis que são chamados de nós.

Para exemplificar a implementação do algoritmo CART, suponha que um conjunto $\{T_b\}_{b=1}^B$ de árvores de classificação é estimado com a finalidade de prever a classe à qual o vetor \mathbf{x}_j pertence. As seguintes etapas são realizadas:

1. Gere randomicamente uma sub-amostra de tamanho n_b a partir dos dados de treinamento.
2. Estime uma árvore de classificação T_b com a amostra simulada seguindo os passos descritos abaixo até que o tamanho mínimo para um nó n_{min}^b seja atingido.
 - a. Selecione aleatoriamente $m \leq p$ variáveis das p variáveis de predição possíveis.
 - b. Tome entre as m variáveis aquela cuja partição é ótima neste nó utilizando o índice de Gini como critério.
 - c. Gere dois sub-nós como resultado da criação da quebra binária.
3. As observações restantes no nó terminal são utilizadas para realização da previsão $T(\mathbf{x}_j, \Theta_b)$ de uma árvore individualmente. Θ_b representa o conjunto de parâmetros contendo as m variáveis selecionadas, os pontos ótimos de partição e as observações em cada nó terminal.
4. A classe prevista para um vetor de entrada \mathbf{x}_j é calculada selecionando o grupo mais votado entre todas as árvores.

2.2.7. SVM

O SVM (*Support Vector Machine*) é baseado em uma transformação dos dados utilizando uma função comumente não linear para a construção de um hiperplano de separação ótimo (Hastie *et al.*, 2009). Por meio da aplicação da transformação $\boldsymbol{\varphi}(\mathbf{x}_j) = \{\varphi_l(\mathbf{x}_j)\}_{l=0}^m$ em um vetor de entrada, com dimensão p , permitir-se-á que padrões não-lineares possam ser linearmente separados em um espaço de variáveis com dimensão superior ao original.

Esse novo espaço de variáveis é denominado espaço de características e possui dimensão $m > p$. A estimativa do hiperplano ótimo $y_j = \mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_j) = \sum_{l=0}^m w_l \varphi_l(\mathbf{x}_j)$, em que $\varphi_0(\mathbf{x}_j) = 1$ e $w_0 = \rho$, pode ser obtida resolvendo o problema de programação quadrática dado pela Eq. (7) (Haykin, 2001).

$$\min_{\mathbf{w}, \xi, \alpha, \gamma} \frac{1}{2} \mathbf{w}^T \mathbf{w} + C(\mathbf{e}^T \xi) + \sum_{i=1}^N \alpha_i [y_i(\mathbf{w}^T \boldsymbol{\varphi}(\mathbf{x}_i)) - 1 + \xi_i] + \sum_{i=1}^N \gamma_i \xi_i \quad (7)$$

Em que \mathbf{e}^T é um vetor de 1, ξ é um vetor contendo as variáveis de folga $\{\xi_i\}_{i=1}^N$, e $\{\alpha_i\}_{i=1}^N$ e $\{\gamma_i\}_{i=1}^N$ são os multiplicadores de Lagrange.

A Eq. (7) é a função Lagrangeana do problema de otimização quadrática primal cujo objetivo é minimizá-la em relação a \mathbf{w} , ξ , $\{\alpha_i\}_{i=1}^N$ e $\{\gamma_i\}_{i=1}^N$. O primeiro termo da equação representa a penalização pela alta complexidade e a constante C (determinada a priori) o *trade-off* entre menores erros de classificação incorreta no processo de treino e o aumento da complexidade do modelo. Tomando as condições de primeira ordem da Eq. (7) é possível obter a função objetivo do problema dual apresentada na Eq. (8).

$$\begin{aligned} & \max_{\alpha} \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(\mathbf{x}_i, \mathbf{x}_j) \\ & \text{s. t} \\ & \sum_{i=1}^N \alpha_i y_i = 0 \\ & 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \end{aligned} \quad (8)$$

Na Eq. (8) $K(\mathbf{x}_i, \mathbf{x}_j) = \sum_{l=0}^m \varphi_l(\mathbf{x}_i) \varphi_l(\mathbf{x}_j) = \boldsymbol{\varphi}^T(\mathbf{x}_i) \boldsymbol{\varphi}(\mathbf{x}_j)$ é chamada de função kernel. Na prática, para implementar um SVM não é necessário conhecer a função $\boldsymbol{\varphi}(\mathbf{x})$, apenas o kernel. Todos os vetores de entrada \mathbf{x}_i cujo $\alpha_i \neq 0$ são chamados vetores de suporte (SV). São essas as observações que definem o hiperplano de separação. O valor de \mathbf{w} pode ser escrito como $\mathbf{w} = \sum_{i=1}^N \alpha_i y_i \boldsymbol{\varphi}(\mathbf{x}_i)$. A classe prevista para um vetor \mathbf{x}_j é calculada utilizando $y_j = \sum_{i=1}^N \alpha_i y_i K(\mathbf{x}_i, \mathbf{x}_j)$. A abordagem utilizada neste trabalho é denominada “um contra um” uma vez que a regra de classificação é estimada pela comparação binária entre pares de grupos. Assim, sendo k o número de grupos, existirão $\frac{k(k-1)}{2}$ hiperplanos de separação.

2.2.8. Seleção do Método de Classificação

A qualidade da classificação de todos os métodos foi avaliada a partir dos critérios conhecidos como resubstituição e *leave-one-out cross validation* (Hastie *et al.*, 2009). O primeiro critério compara a classe prevista pelo modelo com o grupo real de cada elemento utilizado na etapa de treinamento. Dessa forma, essa métrica avalia o erro de classificação dentro da amostra e não garante que o modelo não sofra de super-encaixe (*overfitting*).

A fim de evitar essa complicação, um segundo critério chamado “deixe um de fora” ou *leave-one-out cross validation* foi utilizado – este que é um caso especial da validação cruzada

de k -partes. O procedimento consiste em estimar $n - 1$ modelos sempre expurgando um elemento da amostra de treinamento. O erro de classificação de um modelo é calculado utilizando o erro de previsão apenas da unidade amostral excluída do processo de treino. Esse critério também foi utilizado para seleção dos parâmetros dos métodos *Random Forest* e SVM.

2.2.9. Base de dados

O banco de dados utilizado na análise foi estruturado por meio da coleta, organização e depuração de informações obtidas em balanços auditados publicados periodicamente pelas empresas do setor sucroenergético em diários oficiais, sites das companhias e em outros meios de divulgação.

A amostra utilizada foi composta de 138 empresas que agregam 2.427 unidades industriais em 1.357 balanços financeiros publicados ao longo das safras 2001/2002 a 2018/2019⁵. A Tabela 1 apresenta o número de unidades e os grupos econômicos (demonstrativos financeiros) por safra.

Cabe destacar que não foi possível manter os mesmos grupos econômicos em todos os anos da amostra uma vez que o período foi marcado pela criação, pela fusão/aquisição ou por pedidos de falência e recuperação judicial de empresas. A amostra obtida representa cerca de 54% da produção nacional de cana-de-açúcar (MAPA, 2020) em todo o período.

⁵ Última safra com dados disponíveis até a conclusão do estudo.

Tabela 1: Número de grupos econômicos e usinas por safra.

Safra	Nº de Grupos Econômicos	Nº de Usinas	Produção de cana-de-açúcar amostrada (Milhões de toneladas)	% da produção de cana-de-açúcar	Desvio-Padrão dos Indicadores
01-02	41	57	82	29%	1,59
02-03	44	60	92	29%	1,17
03-04	44	60	100	28%	2,50
04-05	45	61	111	29%	1,89
05-06	49	71	147	39%	2,17
06-07	62	105	178	42%	1,91
07-08	62	114	205	42%	1,76
08-09	69	130	257	45%	2,50
09-10*	92	159	296	49%	22,86
10-11	95	171	348	56%	1,63
11-12	99	184	320	57%	1,91
12-13	100	182	365	62%	1,69
13-14	110	198	429	65%	2,24
14-15	104	193	415	66%	1,87
15-16	98	183	462	69%	1,69
16-17	99	184	460	70%	1,60
17-18	90	174	445	70%	1,81
18-19	84	170	423	68%	2,44
Total	1.387	-	5.136	54%	-

Nota: * Safra escolhida para implementação da análise de *cluster*. O desvio-padrão foi obtido por meio do cálculo da raiz quadrada traço da matriz de covariância dos indicadores financeiros das firmas para cada safra.

Os modelos foram estimados utilizando o software R (R Core Team, 2018). Os seguintes pacotes foram adotados no processo: Corrplot (Wei, 2017), Vegan (Oksanen *et al.*, 2018), *ClusterCrit* (Desgraupes, 2018), randomForest (Liaw e Wiener, 2002), e1071 (Meyer *et al.*, 2017), Dendextend (Galili, 2015), ggPlot2 (Wickham, 2009), klaR (Weihs *et al.*, 2005), e o pacote MASS (Venables e Ripley, 2002).

2.3. ANÁLISE E DISCUSSÃO DOS RESULTADOS

2.3.1. Análise de *Cluster* para a safra 2009/2010

A inspeção visual do dendograma gerado (Figura 1) e a coerência lógica da análise obtida levaram a seleção de 4 grupos de empresas com desempenho econômico-financeiro similar na safra 2009/2010. A Tabela 2 apresenta o resultado dos 11 índices de verificação da qualidade do agrupamento, juntamente a regra utilizada por cada um destes. Cinco dos 11 critérios indicam a escolha de 5 grupos como partição ótima da amostra. Entretanto, vale notar que uma divisão igual ou superior a 5 agrupamentos levaria a classes representativas que conteriam apenas uma empresa. Essa condição, além de distorcer o cálculo dos indicadores na

medida em que um determinado grupo apresentaria variância ou dissimilaridade zero, não é revestida de sentido econômico.

A fim de evitar essa distorção e manter uma maior coerência no uso da técnica para análise dos resultados apenas $k \leq 4$ grupos foram considerados. Neste caso, 4 agrupamentos é a opção ótima apontada pelos índices da Tabela 2.

Tabela 2: Índices de qualidade de *cluster* utilizados para determinar o número ótimo de grupos.

k	<i>Cali-Harab</i>	<i>Gamma</i>	<i>Duda-Hart</i>	<i>Ball-Hall</i>	<i>Ratk-Lanc</i>	<i>Dav-Bould</i>	<i>Trace {W⁻¹B}</i>	<i>Cindex</i>	<i>S-Dbw</i>	<i>Dunn</i>	<i>Marriot</i>
	Máx	Máx	Máx	Máx Diff	Máx	Min	Máx Diff	Min	Min	Máx	Máx Diff
2	27,89	0,36	0,76*	3,74	0,29	1,33	7,47	0,19	1,72	0,03	1,13
3	25,33	0,57	0,63	2,08*	0,31	1,33	6,24	0,14	1,56	0,03	1,20
4	24,23	0,67	0,62	1,34	0,29	1,34	5,36	0,12*	1,17	0,03	1,00
5	41,25*	0,69	0,52	0,68	0,37*	1,04	3,38*	0,19	0,65	0,06*	0,09*
6	39,13	0,71*	0,74	0,50	0,34	0,91*	2,99	0,18	0,52	0,06	0,09
7	35,67	0,66	0,39	0,40	0,32	1,05	2,78	0,17	0,49	0,05	0,08
8	37,20	0,69	0,72	0,30	0,31	1,00	2,39	0,16	0,38*	0,05	0,05

Nota: * Indica o número ótimo de grupos de acordo com o critério respectivo. Para mais detalhes sobre critérios para determinar o número ideal de *cluster* ver Desgraupes (2018), Everitt *et al.* (2011), Milligan e Cooper (1985), Dimitriadou *et al.* (2002), Halkidi *et al.* (2001), Halkidi e Vazirgiannis (2001) e Pascual *et al.* (2010).




Figura 1: Dendrograma dos grupos encontrados para as empresas na safra 2009/2010.

A classificação obtida a partir da análise de agrupamentos para a safra 2009/2010 pode ser avaliada a partir da Tabela 3, que apresenta o valor médio dos indicadores financeiros ponderado pelo *market-share* das empresas para cada um dos grupos identificados.

Tabela 3: Valor médio ponderado dos indicadores financeiros dos grupos na safra 2009/2010.

Tipo de Indicador	Indicador	C1	C2	C3	C4
LIQUIDEZ	Liquidez Corrente	2,16	0,94	0,49	0,47
	Liquidez Geral	1,87	1,78	1,36	0,89
LUCRATIVIDADE	Margem EBIT	0,18	-0,02	0,03	-0,50
	Margem EBITDA	0,26	0,20	0,16	-0,26
	Margem Bruta	0,27	0,13	0,17	-0,01
	Margem Líquida	0,13	0,03	-0,01	-0,47
	Retorno sobre Ativo	0,08	0,02	0,01	-0,13
ENDIVIDAMENTO	Endividamento Geral	0,56	0,61	0,74	1,17
	Endividamento Oneroso	0,58	0,93	1,24	2,03
	Juros por Receita	0,01	0,04	-0,02	0,11
MARKET-SHARE DOS GRUPOS*		12,80%	43,62%	36,41%	7,17%
NÚMERO DE USINAS NO GRUPO		11	25	44	12

**Market-Share* calculado pela proporção da receita do grupo em relação ao total da amostra.

O quarto grupo (C4) tem membros (12 empresas ou 7,17% do *market-share* total) cujo desempenho econômico-financeiro está bastante comprometido. As empresas desse *cluster* possuem o maior endividamento da amostra, comprometendo grande parte da receita com o pagamento de encargos. O endividamento geral acima de 1 (ou 100%) revela que o patrimônio líquido dessas companhias do grupo 4 está, em média, negativo. Além disso, a margem EBIT e margem bruta negativas indicam elevada ineficiência operacional ou má gestão dos custos. Tratam-se, portanto, de empresas com problemas estruturais quanto ao financiamento e operação. O cenário para essas empresas pode ser visto como o de maior criticidade de todas as unidades da amostra.

O terceiro grupo (C3) apresenta liquidez e rentabilidade superiores aos valores do grupo C4, mas aquém dos índices registrados nas empresas do grupo C1 e C2. Esse *cluster* possui um nível de alavancagem alto, margens próximas a zero e liquidez baixa. Trata-se do agrupamento com a maior parte das unidades avaliadas (44 empresas), totalizando cerca de 36,41% do *market-share* amostra.

Os últimos dois agrupamentos, C1 e C2, representam a melhor condição do setor na safra, representando 56,42% do *market-share* amostra (36 grupos econômicos). Embora ambos apresentem semelhanças quanto ao desempenho econômico-financeiro, o principal fator que diferencia essas empresas consiste na forma de financiamento das operações. O grupo 1 (C1) possui níveis de endividamento inferiores, além de concentrar o capital de terceiros do seu balanço no longo prazo, o que justifica os menores encargos financeiros pagos e a maior liquidez corrente.

A Tabela 4 retrata as principais características da performance financeira de cada grupo representativo do setor na safra 2009/2010.

Tabela 4: Resumo das características gerais de cada grupo.

<i>Cluster</i>	Descrição
1	Boas margens líquidas e operacionais; alta liquidez corrente e geral; endividamento baixo (menor da amostra); maior passivo de longo prazo.
2	Boas margens líquidas e operacionais; alta liquidez geral; endividamento moderado; maior passivo de curto prazo.
3	Baixas margens líquidas e operacionais; baixa liquidez corrente e geral; endividamento alto; maior passivo de curto prazo.
4	Margens líquidas e operacionais negativas; liquidez corrente e geral muito baixo; endividamento muito alto; maior passivo de curto prazo.

2.3.2. Classificação com SVM e evolução da situação econômico-financeira do setor sucroenergético brasileiro

O procedimento de validação cruzada conduzido para escolha do algoritmo de classificação tem seus resultados apresentados na Tabela 5.

Tabela 5: Testes de qualidade da classificação.

Método	Resubstituição	<i>Leave-One-Out</i>
Discriminante Canônico de Fisher	90,22%	86,96%
Discriminante Quadrático	93,48%	89,13%
Random Forest	88,04%	88,04%
Máquina de Vetor de Suporte	96,74%	95,65%

Uma vez que a performance do SVM foi a melhor dentre as técnicas testadas, este foi adotado para classificação das empresas. Essa técnica tem ainda a vantagem de não requerer

que as variáveis sejam originadas de qualquer distribuição estatística específica. Essa propriedade é conveniente uma vez que a presença de não normalidade é frequentemente apresentada como um problema no emprego de indicadores financeiros em conjunto a técnicas de estatística multivariada (Barnes, 1987; Horrigan, 1965;1983; Barnes,1982; Eisenbeis, 1977).

A fim de explorar a evolução da situação econômico-financeira da indústria sucroenergética frente as condições de mercado e às políticas públicas observadas durante o período, foi avaliada a variação dos indicadores financeiros em cada agrupamento, a evolução da representatividade de cada *cluster* na amostra e como se caracterizou a migração das empresas entre os grupos. Os hiperplanos estimados como regra de separação são apresentados na Tabela 6.

Tabela 6: Coeficientes estimados do SVM para regra de discriminação entre os grupos.

w_{ij}/f_{ij}	$i = 1 ; j = 2$	$i = 1 ; j = 3$	$i = 1 ; j = 4$	$i = 2 ; j = 3$	$i = 2 ; j = 4$	$i = 3 ; j = 4$
w_{LC}	2,44	1,45	0,36	4,22	1,37	-1,28
w_{EG}	-1,51	-0,37	-0,36	0,13	-1,63	-1,68
w_{LG}	-0,28	0,49	0,36	1,44	0,30	0,61
$w_{DF.F}$	0,06	0,43	-0,10	0,90	-0,43	-0,73
w_{ROA}	0,54	0,10	0,49	-0,44	1,78	1,32
ρ_{ij}	-3,61	-0,95	-0,10	0,43	1,79	1,83

Nota: O *kernel* linear foi utilizado por gerar o menor erro na validação cruzada. Assim, a regra de classificação será dada por: seja \mathbf{x} um elemento amostral (indicadores financeiros de uma empresa normalizados pela média e desvio-padrão) este será classificado para um grupo i ao invés de j se $f_{ij} = \mathbf{x}^T \mathbf{w}_{ij} > \rho_{ij}$, em que f_{ij} é a função que discrimina os grupos i e j com vetor de coeficientes \mathbf{w}_{ij} . Aplicada $f_{ij} \forall i, j$ tal que $i \neq j$ o elemento será alocado para o grupo com maior número de votos.

As regras apresentadas na Tabela 6 formalizam matematicamente o que foi descrito pela Tabela 5. Além disso, o valor dos coeficientes é útil para o entendimento das variáveis que melhor discriminam dois *clusters* e o motivo da migração entre grupos. Quanto maior o valor absoluto do coeficiente, melhor sua capacidade de diferenciar dois agrupamentos.

Com o objetivo de permitir um encaminhamento objetivo e estruturado da análise, nas Figuras 2 e 3 são apresentadas a representatividade de cada *clusters* dentro da amostra em termos de *market-share* e número de empresas. As Figuras 4 a 10, por sua vez, exibem a evolução dos indicadores utilizados no processo de classificação das empresas. Ainda, os índices de endividamento oneroso e margem EBIT são apresentados a fim de retratar a representatividade da dívida financeira e da performance operacional de cada agrupamento selecionado.




Figura 2: Market-share de cada agrupamento entre as safras de 2001/2002 e 2018/2019.

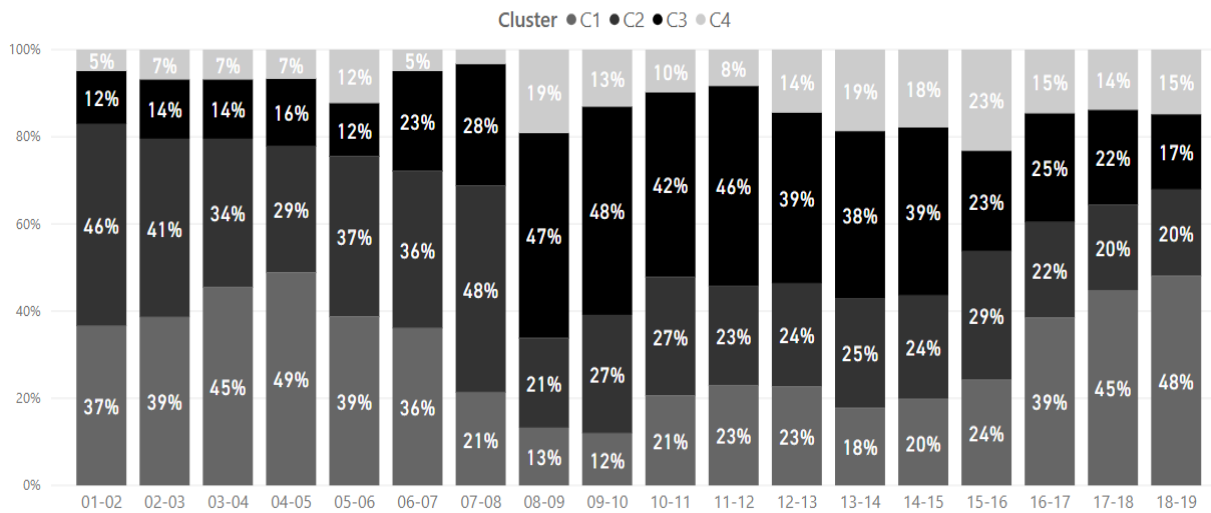


Figura 3: Representatividade do número de empresas por agrupamento entre as safras de 2001/2002 e 2018/2019.




Figura 4: Margem EBIT para os grupos durante as safras de 2001/2002 a 2018/2019.




Figura 5: Retorno sobre Ativo para os grupos durante as safras de 2001/2002 a 2018/2019.

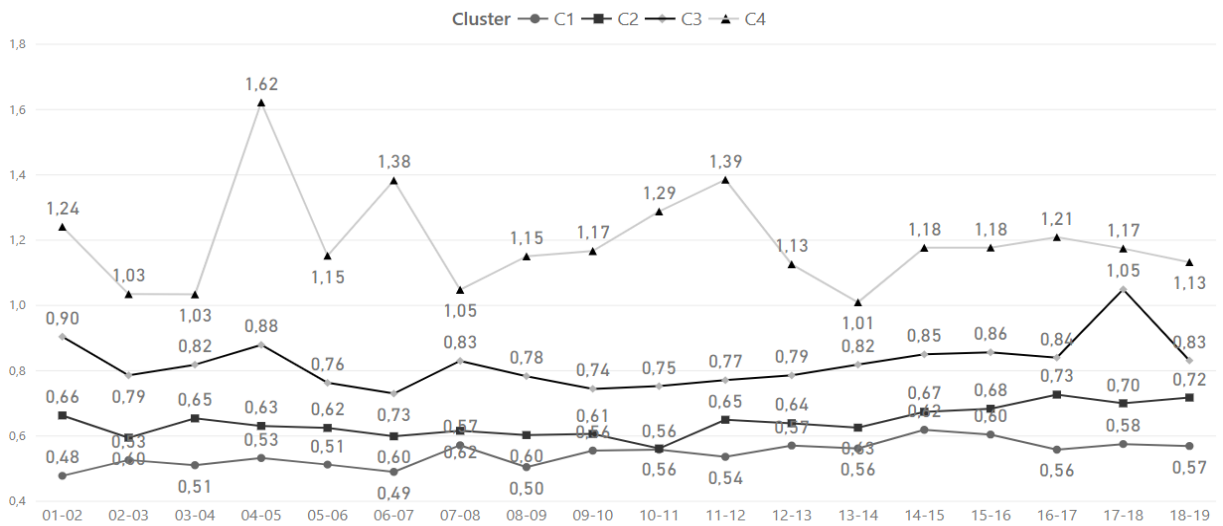


Figura 6: Endividamento Geral para os grupos durante as safras de 2001/2002 a 2018/2019.




Figura 7: Endividamento Oneroso para os grupos durante as safras de 2001/2002 a 2018/2019.

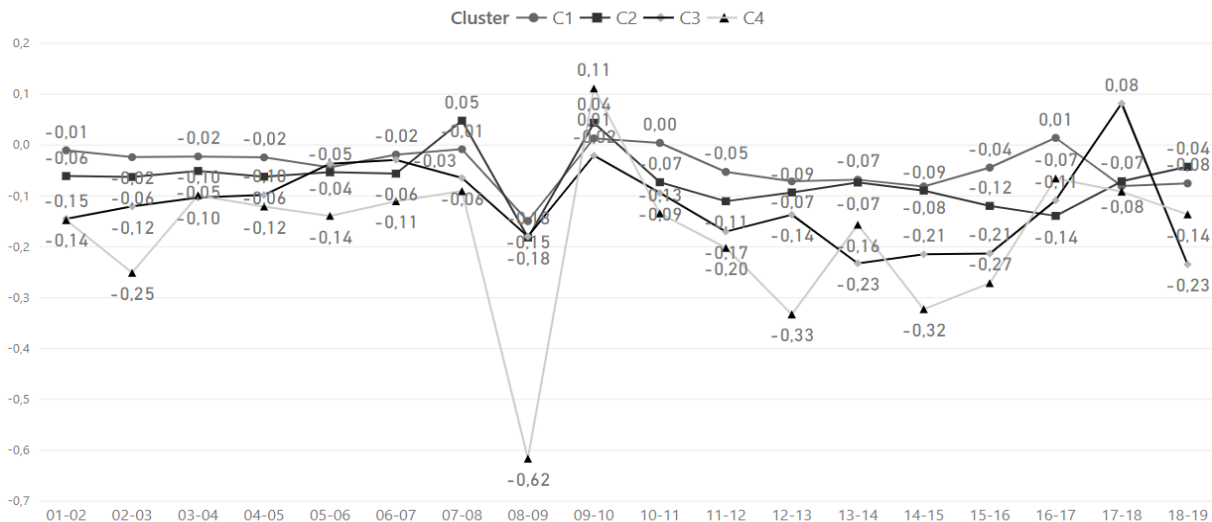


Figura 8: Juros sob Faturamento para os grupos durante as safras de 2001/2002 a 2018/2019.

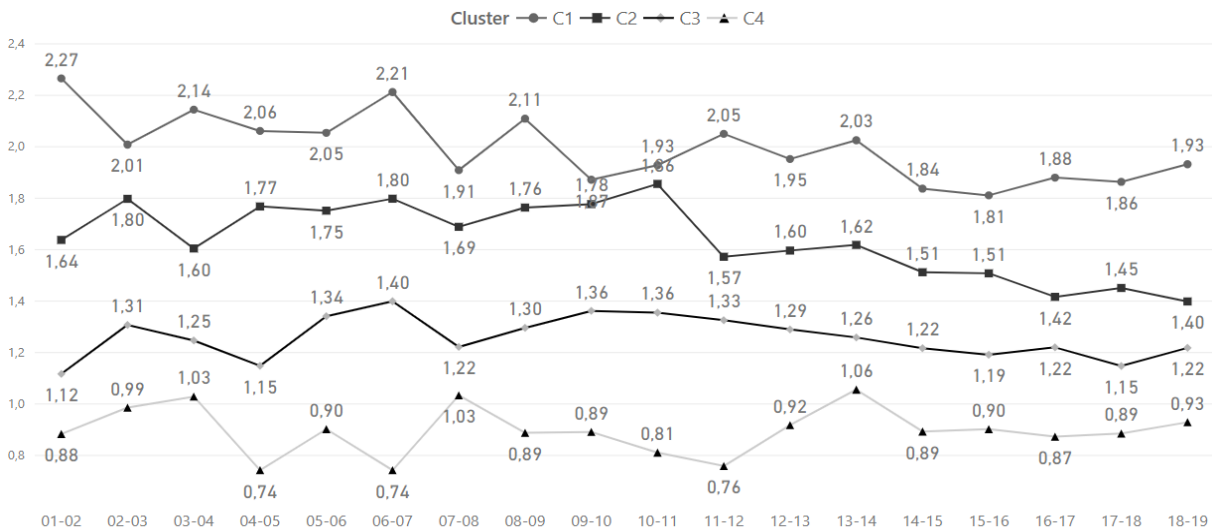


Figura 9: Liquidez Geral para os grupos durante as safras de 2001/2002 a 2018/2019.




Figura 10: Liquidez Corrente para os grupos durante as safras de 2001/2002 a 2018/2019.

Como pode ser observado nas Figuras 2 e 3, até a safra 2005/2006 a proporção de empresas do setor nos agrupamentos 3 e 4 era praticamente desprezível. Nesse período, a representatividade do primeiro *cluster* cresceu até que este viesse a ser o grupo com maior número de empresas. Assim, constata-se que nesse período a maioria dos agentes produtivos desse setor encontravam-se em situação financeira favorável.

Apesar dessa condição, a partir desse momento já era possível verificar um aumento sistêmico no endividamento das empresas em melhores condições (*clusters* 1, 2 e 3), conforme apresentado na Figura 7. Corroborando a essa tendência, já na safra 2007/2008 se observou um crescimento abrupto na participação das empresas no *cluster* 3 e uma redução da representatividade do *cluster* 1.

Essa situação retrata o momento vivenciado pelo setor, caracterizado pelo fluxo intenso de investimento para a expansão da indústria. Segundo Moraes *et al.* (2014), entre 2003 e 2007 foram construídas mais de 100 unidades produtoras no Brasil, além da ampliação da capacidade de inúmeras empresas em operação. Como consequência desse movimento, a moagem de cana-de-açúcar no país passou de 354,7 milhões de toneladas na safra 2003/2004 para 489,2 milhões em 2007/2008 (MAPA, 2020). Nesse mesmo período, o consumo de etanol hidratado cresceu 309,5%, saltando 3,25 bilhões em 2003 para 13,29 bilhões de litros no final do período (ANP, 2020).

Parte dos recursos para essa expansão foram providos pelo setor público, por meio do Banco Nacional de Desenvolvimento Econômico e Social (BNDES) (Neves e Trombim, 2014; Ferracioli *et al.*, 2016; Milanez e Nyko, 2012). Cabe ainda destacar que uma parte dessa ampliação da capacidade produtiva se deu por meio do uso de financiamento de curto prazo, ampliando também a representatividade do grupo 2 na amostra.

Essa expansão foi induzida por diversos fatores, com destaque para o lançamento dos veículos flex-fuel em março de 2003. A iniciativa da indústria automobilística, potencializada pela atuação do poder público por meio da redução do Imposto sobre Produtos Industrializados (IPI) cobrado sobre os automóveis flex, permitiu a consolidação dessa nova tecnologia no mercado brasileiro. Em apenas 4 anos após o seu lançamento, os veículos flex já representavam cerca de 90% das vendas de automóveis no País (ANFAVEA, 2020).

Essa condição fez do Brasil um caso único no mundo não apenas pelo uso do etanol hidratado em larga escala e pela presença dos veículos flex, mas também por contemplar dois combustíveis substitutos - etanol e gasolina - com sistemas de produção completamente

distintos concorrendo em um ambiente de livre mercado diretamente no momento do abastecimento.

A tendência de elevação das cotações internacionais do petróleo no período de 2003 até o início de 2008, e a diferenciação tributária estabelecida domesticamente entre o hidratado e a gasolina, estabeleceram um ambiente de negócios bastante promissor para novos investimentos em expansão da capacidade de produção do biocombustível.

Aliado a esses fatores, destaca-se ainda como indutor da expansão da indústria nesse período a disseminação do interesse mundial pelos combustíveis renováveis diante crescente preocupação mundial com a necessidade de redução das emissões de gases causadores do efeito estufa (GHG), além da expectativa de maior demanda por açúcar brasileiro diante do fim dos subsídios à produção europeia a partir de 2006 (Moraes *et al.*, 2014).

Esse movimento sofreu uma ruptura sem precedentes em 2008, com a instauração da crise financeira internacional, que reduziu a liquidez dos mercados e ampliou expressivamente o custo de crédito em um momento de elevada alavancagem da indústria sucroenergética brasileira e preços pouco remuneradores para seu produto final (Farina *et al.*, 2013).

Essa condição é retratada nos indicadores financeiros das empresas. Após a safra 2006/2007, se observou um aumento expressivo da parcela do mercado correspondente ao terceiro agrupamento (C3), com queda brusca do número de empresas pertencentes ao primeiro grupo (Figuras 2 e 3). No ciclo 2007/2008, a queda do EBIT total da amostra alcançou 149%, conjuntamente com a redução das margens de todos os agrupamentos. O aumento sistemático da representatividade do C4 a partir da safra 2009/2010 também evidencia a piora na condição financeira da indústria nesse período.

Para Moraes *et al.* (2017), esse cenário levou a um amplo processo de consolidação na indústria sucroenergética envolvendo cerca de um terço da produção. Essa condição envolveu a compra de empresas em dificuldades por empresas tradicionais, além da entrada de inúmeros grupos estrangeiros na indústria, incluindo *trading companies*, petroleiras e grandes grupos de outros setores.

Com isso, houve uma mudança no fluxo de investimentos do setor, que antes eram direcionados à construção de novas unidades e após a crise passaram a ser empregados para a compra de empresas em dificuldade.

O momento pós crise financeira mundial, por sua vez, deu início a um outro período de mudanças no arcabouço institucional brasileiro, caracterizado pela intensificação da intervenção estatal por meio do controle dos preços da gasolina no mercado doméstico. Primeiramente, houve a redução dos impostos incidentes sobre o derivado e, em um segundo

momento, dada a impossibilidade de novas reduções de tributos, a Petrobrás passou a praticar preços inferiores aqueles vigentes no mercado internacional, com a defasagem chegando a atingir cerca de 30% em alguns meses (Rodrigues e Bacchi, 2016). Esse movimento promoveu deterioração da competitividade do etanol hidratado e perda de quase R\$ 10 bilhões de receita anual em um momento de aumento constante dos custos de produção do biocombustível e de elevada alavancagem financiamento pelo setor produtivo (Veiga Filho, 2014 *apud* Ramos, 2016).

Nesse cenário, não existiam incentivos econômicos para a construção de novas unidades produtoras, que, via de regra, são mais dependentes do etanol devido a pior condição logística para o escoamento do açúcar a partir das regiões onde ocorre a expansão da produção. Adicionalmente, nos anos subsequentes o setor se deparou com um período de *superávit* no mercado do adoçante, com redução nos preços recebidos pelo produtor e queda na produtividade agrícola da lavoura.

Além das adversidades climáticas comuns a qualquer setor agrícola, essa queda de produtividade foi induzida pela falta de recursos para a renovação do canavial e pela curva de aprendizagem imposta pela acelerada ampliação da colheita mecanizada visto a exigência de extinção da queima da cana-de-açúcar como prática de despalha para a colheita (CTC, 2018).

A situação descrita levou a um aumento crescente do endividamento das unidades e do custo associados ao financiamento de suas operações, com conseqüente aumento da representatividade de C3 e C4. A dívida total da amostra se elevou em aproximadamente 330% (R\$ 81,67 bilhões) no período entre 2007 e 2015. O endividamento oneroso da amostra passou de 60% para 127%.

As empresas do pior agrupamento (C4) chegaram a comprometer mais de 30% do seu faturamento com o pagamento dos serviços da dívida na safra 2014/2015. Adicionalmente, o índice de endividamento geral desse grupo permaneceu acima de 1 durante todo o período analisado, indicando a existência de passivo à descoberto. Como consequência, nota-se um elevado número de pedidos de recuperação judicial por parte das empresas pertencentes a esse agrupamento.

O grupo 3, por sua vez, o qual se encontrava a maior parte das empresas da amostra no início do período, apresentaram, após o ciclo 2009/2010, um nível de endividamento que superou o faturamento anual das companhias e despesas financeiras que comprometem até 21% da sua receita. O resultado dessa situação pode ser visto por meio do indicador de retorno sobre o ativo, que, a despeito da margem EBIT positiva, registrou retorno líquido negativo de 3% na safra 2014/2015.

Até mesmo os grupos 1 e 2, considerados os mais saudáveis do setor, apresentam um quadro crítico no período pós-crise financeira. Após a safra 2009/2010, há um aumento considerável no nível de endividamento das empresas desses dois grupos, que flutua acima dos 60% do faturamento anual em todo período. Embora o retorno sobre ativo não tenha sido negativo, a intensa redução das margens afetou a atratividade para novos investidores e a capacidade de investimento das empresas desses grupos.

É importante destacar que entre safras 2010/2011 e 2014/2015 pode-se ter a falsa impressão de melhora da condição da indústria devido ao aumento do *market-share* do C1 e a queda na participação do C3. Contudo, isso aconteceu primeiro porque houve uma migração de algumas empresas de C3 para C4 e, segundo, observou-se um movimento de concentração dos grandes grupos econômicos em C1 (que acaba por elevar a parcela de mercado pertencente ao grupo).

De fato, as medidas adotadas nesse período repercutiram com piora sistêmica nos índices e na composição dos grupos representativos da indústria sucroenergética. No período datado entre 2008 e 2015 houve o fechamento de 96 unidades produtoras no Brasil (EPE, 2020b).

Após o auge do que pareceu ser uma das maiores crises da história da indústria sucroenergética brasileira, algumas mudanças começaram a ser observadas a partir do ciclo agrícola 2015/2016 nos mercados de açúcar e de etanol. Ajustes de gestão e no quadro de colaboradores das unidades produtoras e condições climáticas favoráveis acarretaram uma melhoria na produtividade agrícola nesta mesma safra, com consequente repercussão nos custos de produção.

No tocante às mudanças no arcabouço institucional vigente, se destaca aquela relacionada ao reajuste no preço doméstico da gasolina que passou a ser efetuado pela Petrobrás em outubro/2016 após a estatal sofrer graves prejuízos. Em julho/2017, os ajustes começaram a ser realizados diariamente para evitar a perda de *market-share* da empresa.

No ano de 2015, o governo e diversos estados retornaram a diferenciação tributária existente entre etanol e gasolina. Em 2017, a ampliação do déficit público exigiu um novo aumento nos tributos federais sobre a gasolina. Apesar de não ser o objetivo das medidas, esse movimento ampliou a competitividade do etanol no mercado doméstico.

Por fim, os preços do açúcar recebidos pelos produtores brasileiros melhoraram substancialmente nas safras 2016/2017 e 2017/2018 devido desvalorização do Real e o aumento nas cotações internacionais do produto frente ao ciclo de *déficit* mundial de produção. Mesmo após a estabilização do mercado do adoçante e retorno ao novo *superávit* da oferta, no ciclo

2018/2019, uma boa perspectiva foi mantida para o setor por conta dos bons preços dos biocombustíveis no mercado doméstico. O preço da gasolina no Brasil, agora definido pela cotação internacional do petróleo, deu sustentação a competitividade do etanol hidratado, que alcançou o maior pico de consumo da série histórica atingindo 22,5 bilhões de litros comercializados (ANP, 2020).

Como resultado dessas mudanças, observou-se um aumento expressivo do *market-share* do agrupamento C1 nas últimas duas safras da amostra, que passou a deter a maior parcela do mercado e o maior número de empresas como membros. Adicionalmente, ocorreu uma melhora generalizada nos indicadores de lucratividade e rentabilidade dos grupos nesse período, acompanhada de queda no endividamento da indústria - a dívida onerosa reduziu em 5,8% (R\$ 4,77 bilhões) no período, passando a representar 86% da receita das empresas da amostra.

De modo geral, pode-se afirmar que o cenário mais otimista observado entre as safras 2015/2016 e 2018/2019 permitiu uma redução da alavancagem e aumento da rentabilidade média da indústria, com muitas empresas migrando para os grupos de melhor situação financeira (grupo C1 e C2). Essas mudanças pontuais, entretanto, não foram suficientes para garantir a revitalização da indústria toda, uma vez que 33% do *market-share* e 32% dos grupos econômicos se encontram em uma situação econômico-financeira ainda delicada.

2.4. CONSIDERAÇÕES FINAIS

Os resultados obtidos neste estudo revelaram como evoluiu a condição econômico-financeira do setor sucroenergético brasileiro nos últimos 18 anos, contraponto as mudanças observadas na conjuntura econômica, nas condições produtivas e no conjunto de políticas públicas com impacto no mercado de etanol, especialmente.

A análise dos resultados evidencia quatro fases determinantes para a performance financeira do setor sucroenergético e formação da estrutura da indústria em 4 *clusters*. A primeira delas foi marcada pela introdução da frota flex no mercado brasileiro no início dos anos 2000 e pelo crescimento da representatividade do cluster C1.

A consolidação da frota flex, entretanto, impôs uma relação direta e imediata entre a receita do produtor e as condições vigentes no mercado de gasolina. Como consequência dessa mudança, nos anos posteriores diversas medidas de política econômica ou medidas voltadas ao mercado de gasolina passaram a alterar substancialmente a estrutura econômico-financeira do setor sucroenergético que, com intuito de aproveitar o momento favorável ao biocombustível havia elevado seu endividamento e reduzido a liquidez dos balanços. Esses fatores foram

fundamentais para marcar a segunda fase vivenciada pelo setor referente a ruptura na condição financeira das empresas em 2008, com a crise financeira internacional.

Como consequência, nesse momento foi observada queda nas margens de lucro, aumento da representatividade dos *clusters* com maiores dificuldades financeiras e a saída de empresas da amostra devido ao intenso movimento de consolidação no setor, com a fusão e fechamento de unidades produtoras.

No período pós crise financeira, destacado como a terceira fase determinante para a indústria, as políticas econômicas contra-cíclicas adotadas no país reacenderam a preocupação com o controle inflacionário. Como consequência, se viu a administração do preço dos derivados no mercado interno, desonerações de tributos sobre a gasolina e a prática de valores internos inferiores aqueles praticados internacionalmente, conferindo, inclusive, perdas financeiras nas importações de gasolina pela Petrobrás.

Essa condição prejudicou substancialmente a situação econômico-financeira da indústria sucroenergética, aumentando o endividamento das empresas e reduzindo sua rentabilidade. Como consequência, houve o aumento da representatividade dos *clusters* C3 e C4.

A partir de 2015, entretanto, uma nova mudança na orientação econômica passar a ser observada no país. A preocupação com o controle inflacionário dá lugar à necessidade de aumento de receitas para redução do *déficit* público. Essa condição, mais evidente após o processo eleitoral no final de 2014, estabeleceu um período de aumentos recorrentes nos tributos sobre combustíveis, com maior incidência sobre a gasolina. Nesse mesmo momento, as perdas impostas à Petrobrás exigiram a implementação de uma nova política de preços domésticos para os derivados, alinhando os valores internos aqueles vigentes no mercado internacional.

Essa condição, aliada à melhoria nos preços mundiais do açúcar, é refletida na condição financeira das empresas produtoras de etanol, com redução das despesas financeiras, melhoria das margens operacionais e migração das empresas para os *clusters* com melhor saúde financeira nas safras 2015/2016 a 2018/2019.

A despeito da melhora dos indicadores da indústria no período recente, é necessário destacar que na última safra analisada, 17% e 15% das empresas ainda pertenciam ao C3 e C4, respectivamente. O primeiro trata-se do grupo que apresenta margens líquidas negativas e endividamento geral médio de 83%. Quanto ao C4, mesmo com uma melhora das margens e redução do endividamento, as empresas desse grupo ainda vivenciam uma situação

insustentável para seu crescimento e desafiadora para sua continuidade, pois operam com margens líquidas, margens operacionais e patrimônio líquido negativos.

Além disso, é importante destacar que 22 empresas originalmente contempladas pelo espaço amostral deste estudo não estão sendo contabilizadas na safra 2018/2019 devido a situação de recuperação judicial, que desobriga a divulgação dos demonstrativos financeiros. Apesar do percentual de 15% das empresas em C4, quando considerados estas companhias como membros “ocultos” desse grupo, sua representatividade se eleva para 33%. Somado à C3, portanto, resulta em 47% das empresas em grupos de saúde financeira em estado mais complicado.

Nesse sentido, uma parte considerável das empresas deve ter dificuldade para aportar recursos visando a ampliação de capacidade de produção no curto prazo, uma vez que o foco das companhias está na redução do endividamento na estrutura de capital. As empresas de C2, em especial, embora estejam em condições financeiras confortáveis para sua continuidade, não devem desempenhar um crescimento substancial da produção no curto prazo, visto o baixo índice de rentabilidade nos últimos anos.

A situação sugere que investidores externos à indústria que desejam aportar recursos podem priorizar a aquisição de empresas já existentes e em condição financeira prejudicada ao invés de investimentos para a construção de novas unidades produtoras. Nessa condição, a sistemática de classificação implementada ao longo desse estudo pode ser bastante útil para a realização de *benchmarking* das empresas em operação, direcionando eventuais operações de compra e concessão de crédito, além de permitir aos gestores das unidades em operação a definição de um padrão de metas e diretrizes objetivas em seu planejamento.

Os resultados evidenciam que a condição financeira atual do setor é bastante heterogênea. A maior parte das empresas possuem potencial para readequação financeira e crescimento da produção no longo prazo. Todavia, as condições observadas na safra 2018/2019 sugerem que 52% das empresas (62% se considerados os membros ocultos de C4), isto é, C2, C3 e C4, não possuem condições de elevar sua produção de forma substancial no curto prazo.

Nesse ponto, a implementação da Política Nacional de Biocombustíveis pode estabelecer um novo marco para o setor sucroenergético ao definir uma estratégia de longo prazo para o uso de biocombustíveis no país. Essa é uma condição fundamental para o atendimento das metas de descarbonização previstas e para um novo ciclo de investimento na produção de etanol diante das alterações constantes de políticas públicas nos últimos anos, com medidas delineadas para atender a interesses, na maior parte das vezes, dissociadas da garantia do abastecimento interno.

REFERÊNCIAS

- Altman, E.I. (1968). “Financial ratios, discriminant analysis e the prediction of corporate bankruptcy”. *The journal of finance* 23(4): p. 589-609. <https://doi.org/10.1111/j.1540-6261.1968.tb00843.x>
- Altman, E.I. Marco, G. Varetto, F. (1994). “Corporate distress diagnosis: Comparisons using linear discriminant analysis e neural networks (the Italian experience)”. *Journal of banking & finance* 18(3): p. 505-529. [https://doi.org/10.1016/0378-4266\(94\)90007-8](https://doi.org/10.1016/0378-4266(94)90007-8)
- ANFAVEA – Associação Nacional dos Fabricantes de Veículos Automotores (2020). “Estatísticas”. <http://www.anfavea.com.br/anuario2020/anuario.pdf> (Acesso em 31 de Outubro de 2020).
- Angelo, C.F.D. Sanvicente, A.Z. (1992). “Conduta e desempenho de empresas: uma aplicação de “*cluster analysis*” à segmentação da indústria do cimento”. *Estudos Econômicos* 22(1): p. 107-128.
- ANP – Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (2020). “Dados Estatísticos”. <http://www.anp.gov.br/dados-estatisticos> (Acesso em 31 de Outubro de 2020).
- BACEN – Banco Central do Brasil (2020) “Histórico de Estatísticas”. <https://www.bcb.gov.br/estatisticas/historicoestatisticas> (Acesso em 31 de Outubro de 2020).
- Barnes, P. (1982). “Methodological Implications of Non-Normally Distributed Financial Ratios”. *Journal of Business Finance e Accounting* 9(1): p. 51-62. <https://doi.org/10.1111/j.1468-5957.1982.tb00972.x>.
- Barnes, P. (1987). “The analysis e use of financial ratios: A review article”. *Journal of Business Finance & Accounting* 14(4): p. 449-461. <https://doi.org/10.1111/j.1468-5957.1987.tb00106.x>.
- Bodie, Zvi. Kane, Alex. Marcus, Alan J. (2015). *Investimentos*. 10th ed. Porto Alegre: AMGH.
- Boillat, P.Y. Skowronski, N. Tuchschimid, N. (2002). “*Cluster analysis*: Application to sector indices e empirical validation”. *Financial Markets e Portfolio Management* 16(4): p. 467-486. <https://doi.org/10.1007/s11408-002-0403-4>
- Breiman, L. (2001). “Random Forests”. *Machine Learning* (45): p. 5-32. <https://doi.org/10.1023/A:1010933404324>
- Breiman, Leo. (1984). *Classification e Regression Trees*. 1th ed. Boca Raton: CRC Press.
- Bressan, Filho, A. (2009). “Os Fundamentos da crise do setor sucroalcooleiro no Brasil”. National Company of Supplying Report.
- Callado, A.A.C. Callado, A.L.C. Mendes, E. (2015). “Padrões de uso de indicadores de desempenho: Uma abordagem multivariada para empresas agroindustriais do setor avícola localizadas no estado de Pernambuco”. *Latin American Journal of Business Management* 6(2): p. 201-236.
- Campos, K.C. (2014). “Índice de desempenho econômico-financeiro: Melhores e piores empresas no Brasil”. *Revista de Administração da UEG, Aparecida de Goiânia* 4(3): p. 28-47.

Capece, G. Cricellib, L. Di Pillo, F. (2010). “A *cluster* analysis study based on profitability e financial indicators in the Italian gas retail market”. *Energy Policy* 38(7): p. 3394-3402. <https://doi.org/10.1016/j.enpol.2010.02.013>

Carvalho, F.L.D. Bialoskorko, S. (2007). “Identificação dos principais indicadores para avaliação de desempenho financeiro de cooperativas agropecuárias”. *Revista de Economia e Sociologia Rural* 45(1): p. 119-138.

CNPE – Conselho Nacional de Política Energética (2020). “Resolução No 8, de 18 de agosto de 2020”. <http://www.mme.gov.br/web/guest/conselhos-e-comites/cnpe/resolucoes> (Acesso em 19 de Agosto de 2020).

Corrar, J.L. Pohlmann, M.C. (2004). “Análise *cluster* de setores da economia brasileira utilizando indicadores contábeis”. XXVIII Encontro da Associação Nacional de Programas de Pós-Graduação em Administração; p. 1-25.

CRBIO – Cômite RenovaBio (2020). “Consulta Pública No 94 de 5 de junho de 2020”. <http://www.mme.gov.br/web/guest/conselhos-e-comites/crbio> (Acesso em 19 de Agosto de 2020).

CTC – Centro de Tecnologia Canavieira (2018). “Panorama da Safra e Perspectivas”. <https://unica.com.br/publicacoes/> (Acesso em 31 de Outubro de 2020).

Desgraupes, B. (2018). “*clusterCrit: Clustering Indices*. R package version 1.2.8”. <https://CRAN.R-project.org/package=clusterCrit> (Acesso em 10 de Janeiro de 2018).

Dimitriadou, E. Doldicar, S. Weingessel, A. (2002). “An examination of indexes for determining the number of *clusters* in binary data sets”. *Psychometrika* (1): p. 137-159. <https://doi.org/10.1007/BF02294713>.

Edmister, R.O. (1972). “Financial ratios as discriminante predictors of small business failure”. *Journal of Finance* 27(1): p. 139-140. <https://doi.org/10.1111/j.1540-6261.1972.tb00633.x>

Eisenbeis, R.A. (1977). “Pitfalls in the application of discriminant analysis in business, finance, e economics”. *The Journal of Finance* 32(3): p. 875-900. <https://doi.org/10.1111/j.1540-6261.1977.tb01995.x>.

Elliott, Barry. Elliott, Jamie. (2011). *Financial accounting e reporting*. 14th ed. London: Prentice Hall Financial Times.

EPE – Empresa de Pesquisa Energética (2020a). “Balanço Energético Nacional 2020: Ano base 2019”. <http://www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/balanco-energetico-nacional-2019> (Acesso em 31 de Outubro de 2020).

EPE – Empresa de Pesquisa Energética (2020b). “Cenários de Oferta de Etanol e Demanda do Ciclo Otto”. www.epe.gov.br/pt/publicacoes-dados-abertos/publicacoes/cenarios-oferta-etanol-e-demanda-ciclo-otto (Acesso em 31 de Outubro de 2020).

Everitt, Brian S. Landau, Sabine. Leese, Morven. Stahl, Daniel. (2011). *Cluster Analysis*. 5th ed. West Sussex: John Wiley e Sons.

Farina, E.M.M.Q. Rodrigues, L. Souza, E.L. (2013). “A Política de Petróleo e a Indústria de Etanol no Brasil”. *Interesse Nacional* (1). p. 64-75.

Ferracioli, K.G. Bacha, C.J.C. Jacomini, R.L. (2016). “Linhas de crédito do BNDES para o setor sucroenergético brasileiro”. *Revista de Política Agrícola* (3): p. 52-61.

Fisher, R.A. (1936). “The use of multiple measurements in taxonomic problems”. *Annals of Human Genetics* 7(2): p. 179-188. <https://doi.org/10.1111/j.1469-1809.1936.tb02137.x>

Fridson, Martin. Alvarez, Fernando. (2002). *Financial Statement Analysis: A Practitioner's Guide*. 3th ed. New York: John Wiley & Sons.

Frydman, H. Altman, E.I. Kao, D. (1985). “Introducing Recursive Partitioning for Financial Classification: The Case of Financial Distress”. *The Journal of Finance* 40(1): p. 89-97. <https://doi.org/10.1111/j.1468-5957.1984.tb00059.x>

Galili, T. (2015). “dendextend: an R package for visualizing, adjusting, e comparing trees of hierarchical *clustering*”. *Bioinformatics* (22): p. 1-2. <https://doi.org/10.1093/bioinformatics/btv428>.

Guedes, S.N.R. Périco, E.A. Peres, F.B. Dos Santos, R.G. (2016). Trajetória de indicadores econômico-financeiros na agroindústria brasileira: O caso do grupo Cosan. In: Santos, R.G. Quarenta anos de etanol em larga escala no Brasil: desafios, crises e perspectivas, São Paulo: IPEA; p. 83-111.

Gupta, M.C. Huefner, R.J. (1972). “A *cluster* analysis study of financial ratios e industry characteristics”. *Journal of Accounting Research* 10(1): p. 77-95. <https://doi.org/10.2307/2490219>

Halkidi, M. Batistakis, Y. Vazirgiannis, M. (2001). “On *clustering* validation techniques”. *Journal of Intelligent Information Systems* (2): p. 107-145. <https://doi.org/10.1023/A:1012801612483>

Halkidi, M. Vazirgiannis, M. (2001). “*Clustering* validity assessment: finding the optimal partitioning of a data set”. *IEEE International Conference on Data Mining*; San Jose. <https://doi.org/187-194.10.1109/ICDM.2001.989517>.

Hastie, Trevor. Tibshirani, Robert. Friedman, Jerome. (2009). *The Elements of Statistical Learning: Data Mining, Inference, e Prediction*. 2th ed. New York: Springer.

Healy, Paul M. Palepu, Krishna G. (2012). *Business Analysis Valuation: Using Financial Statements*. 5th ed. Mason: Cengage Learning.

Higgins, Robert C. (2014). *Análise para administração financeira*. 10th ed. Rio de Janeiro: AMGH.

Horrigan, J.O. (1965). “Some empirical bases of financial ratio analysis”. *The Accounting Review* 40(3): p. 558-568.

Horrigan, J.O. (1968). “A Short History of Financial Ratio Analysis”. *The Accounting Review* 43(2): p. 284-294.

Horrigan, J.O. (1983). “Methodological Implications of Non-Normally Distributed Financial Ratios: A comment”. *Journal of Business Finance e Accounting* 10(4): p. 683-689. <https://doi.org/10.1111/j.1468-5957.1982.tb00972.x>.

- Hsu, C.F. Hung, H.F. (2009). “Classification Methods of Credit Rating - A Comparative Analysis on SVM, MDA e RST”. 2009 International Conference on Computational Intelligence e Software Engineering. <https://doi.org/10.1109/CISE.2009.5366068>
- Johnson, Richard A. Wichern, Dean W. (2007). Applied Multivariate Statistical Analysis. 6th ed. New Jersey: Pearson Education.
- Klecka, William R. (1980). Discriminant Analysis. 19th ed. Newbury Park: Sage Publications.
- Lance, G. N. e Williams, W. T. (1967) “A general theory of classificatory sorting strategies: 1. Hierarchical systems”. Computer Journal 9(4), 373–380.
- Laurent, C.R. (1979). “Improving the efficiency e effectiveness of financial ratio analysis”. Journal of Business Finance & Accounting 6(3): p. 401-413. <https://doi.org/10.1111/j.1468-5957.1979.tb01099.x>
- Liaw, A. Wiener, M. (2002). “Classification e Regression by randomForest”. R News (2): p. 18-22.
- Liu, C. Chan, Y. Kazmi, S.H.A. Fu, H. (2015). “Financial Fraud Detection Model: Based on Random Forest”. International Journal of Economics e Finance 7(7): p. 178-188. <https://doi.org/10.5539/ijef.v7n7p178>
- MAPA – Ministério da Agricultura, Pecuária e Abastecimento (2020). “Desenvolvimento Sustentável – Agroenergia”. www.agricultura.gov.br (acessado em 31 de Outubro de 2020).
- Martins, H.H. Goes, T.H.M. Shikida, P.F.A. Gimenes, R.M.T. Piacenti, C.A. (2015). “Estrutura de capital e alavancagem financeira de empresas da agroindústria canavieira: um estudo multicaso para o centro-oeste”. Gestão & Regionalidade 31(93): p. 76-93. <https://doi.org/10.13037/gr.vol31n93.2430>
- Meyer, D. Dimitriadou, E. Hornik, K. Weingessel, A. Leisch, F. (2017). e1071: Misc Functions of the Department of Statistics, Probability Theory Group. R package version 1.6-8. <https://CRAN.R-project.org/package=e1071>.
- Milanez, Artur Yabe. Nyko, Diego. (2012). O futuro do setor sucroenergético e o papel do BNDES. in: De Sousa, Felipe Lage. BNDES 60 anos: perspectivas setoriais. Rio de Janeiro: BNDES; p. 62-87.
- Milligan, G.W. Cooper, M.C. (1985). “An examination of procedures for determining the number of *clusters* in a data set”. Psychometrika 50(2): p. 159-179. <https://doi.org/10.1007/BF02294245>.
- Moraes, M.L. Bacchi, M.R.P. (2014). “Etanol, do início às fases atuais de produção”. Revista de Política Agrícola 23(4): p. 5-22.
- Moraes, Márcia Azanha F. Zilberman, David. Rodrigues, Luciano. (2014). The free market: The profound changes e the new agenda. In: Moraes, Márcia Azanha F. Zilberman, David. Production of ethanol from sugarcane in Brazil: From state intercession to a free market. New York: Springer; p. 149-193.
- Moraes, Márcia Azanha Ferraz D. Rodrigues, Luciano. Kaplan, Scott. (2017). The sugarcane industry e the use of fuel ethanol in Brazil: history, challenges, e opportunities. In: Khanna

Madhu, Zilberman David. Handbook of Bioenergy Economics e Policy: Volume II. New York: Springer; p. 39-63.

MTPS – Ministério do Trabalho e Previdência Social (2020). “Relação Anual de Informações Sociais – RAIS”. pdet.mte.gov.br (Acesso em 31 de Outubro de 2020).

Nascimento, D. (2014). “Crise nas usinas chega à Justiça”. Revista RPA News: p. 6-13.

Nastari, P. (2014). *Avaliação e perspectivas do setor sucroenergético*. Câmara Setorial de Açúcar e Álcool do Ministério da Agricultura, Pecuária e Abastecimento.

Neves, M.F. Trombim, V.G. (2014). “A Dimensão do Setor Sucroenergético: Mapeamento e quantificação da safra 2013/2014”. São Paulo: FEA-RP.

Noriller, R.M. Chaebo, G. Bastos, S.P.S. Lopes, A.C.L.V. Hall, R.J. (2011). “Comparação econômico-financeira por índices-padrão de usinas sucroenergéticas listadas na BM&F Bovespa S.A.”. Revista de Administração da UEG 2(2): p. 58-78.

Oksanen, J. Blanchet, F.G. Kindt, R. Legendre, P. Minchin, P.R. O'Hara, R.B. Simpson, G.L. Solymos, P. Stevens, M.H.H. Wagner, H. (2018). “Vegan: Community Ecology Package. R package version 2.5-3”. <https://CRAN.R-project.org/package=vegan> (Acesso em 15 de Novembro de 2018).

Pascual, D. Pla, F. Sánchez, J.S. (2010). “Cluster validation using information stability measures”. Pattern Recognition Letters (6): p. 454-461. <https://doi.org/10.1016/j.patrec.2009.07.009>.

PLURAL – Associação Nacional das Distribuidoras de Combustíveis, Lubrificantes, Logística e Conveniência (2018). “Dados do Setor”. <https://somosplural.com.br/dados-do-setor/> (Acesso em 12 de Julho de 2018).

R Core Team. (2018). “R: A language e environment for statistical computing”. <https://www.R-project.org/> (Acesso em 10 de Novembro de 2018).

Ramos, Pedro. (2016). Trajetória e situação atual da agroindústria canavieira do Brasil e do mercado de álcool carburante. In: Santos, Gesmar Rosa. Quarenta anos de etanol em larga escala no Brasil: desafios, crises e perspectivas. São Paulo: IPEA; p. 47-82.

Rodrigues, L. Bacchi, M.R.P. (2016). Light fuel demand e public policies in Brazil, 2003-2013. Applied Economics (54): p. 5300-5313. <https://doi.org/10.1080/00036846.2016.1176115>.

Rodrigues, L. Bacchi, M.R.P. (2017) “Analyzing light fuel demand elasticities in Brazil using cointegration techniques”. Energy Economics (1): p. 322-331. <https://doi.org/10.1016/j.eneco.2017.02.012>.

Rodrigues, L. Rodrigues, L. (2018). “Economic-financial performance of the Brazilian sugarcane energy industry: An empirical evaluation using financial ratio, cluster e discriminant analysis”. Biomass e Bioenergy 108: p. 289-296. <https://doi.org/10.1016/j.biombioe.2017.11.013>

Salmi, T. Dahlstedt, R. Luoma, M. Laakkonen, A. (1986). “Financial ratio variability e industry classification”. Finnish Journal of Business Economics 35(4): p. 333-356.

Simon, Haykin (2001). Redes Neurais: Princípios e Prática, 2th ed. Porto Alegre: Bookman.

Sook Lu, Y. (2012). *A latente class cluster analysis study of financial ratios e industry classifications between Japan e Malaysia*. Japan Center for Economic Research; p. 1-52.

Taffler, R. (1982). “Forecasting company failure in the UK using discriminant analysis e financial ratio data”. *Journal of the Royal Statistical Society* 145(3): p. 342-358. <https://doi.org/10.2307/2981867>

USDA – United States Department of Agriculture (2020). “Sugar e Sweeteners Outlook”. <https://www.ers.usda.gov> (Acesso em 31 de Outubro de 2020).

Venables, Bill. Ripley, Brian. (2002). *Modern Applied Statistics with S*. 4th ed. New York: Springer.

Ward, J.H. (1963). “Hierarchical grouping to optimize an objective function”. *Journal of the American Statistical Association* 58(301): p. 236-244.

Wei, T. (2017). “Corrplot: Visualization of a correlation matrix. R package version 0.84”. <https://CRAN.R-project.org/package=corrplot> (Acesso em 02 de Novembro de 2018).

Weih, C. Ligges, U. Luebke, K. Raabe, N. (2005). *klaR Analyzing German Business Cycles*. In: Baier, D. Decker, R. Schmidt-Thieme, L. *Data Analysis e Decision Support*. Berlin: Springer; p. 335-343. https://doi.org/10.1007/3-540-28397-8_36

Wickham H. *ggplot2: Elegant Graphics for Data Analysis*. New York: Springer; 2009.

Wild, John J. Subramanyam, K.R. (2008). *Financial Statement Analysis*. 10th ed. New York: McGraw-Hill.

Xie, C. Luo, C. Yu, X. (2011). “Financial distress prediction based on SVM e MDA methods: the case of Chinese listed companies”. *Quality & Quantity* (3): p. 671–686. <https://doi.org/10.1007/s11135-010-9376-y>

Zhang, L. Hu, H. Zhang, D. (2015). “A credit risk assessment model based on SVM for small e medium enterprises in supply chain finance”. *Financial Innovation* (1): p. 1-14. <https://doi.org/10.1186/s40854-015-0014-5>

Zuge, M. Neto, A.C. (2011). “Utilização de métodos estatísticos multivariados na avaliação do desempenho empresarial”. *Revista Paranaense de Desenvolvimento* (97): p. 101-112.

3. MÉTODOS DE PREVISÃO APLICADOS AO CONSUMO BRASILEIRO DE COMBUSTÍVEIS LEVES

Resumo

A previsão da demanda de combustíveis é fundamental para nortear planejamento e investimentos na área empresarial, além de ações públicas visando a garantia de abastecimento. Isso posto, neste estudo foram avaliados diferentes métodos de previsão para o consumo de combustíveis leves no Brasil (combustíveis utilizados pelos veículos com motor de combustão interna ou ciclo Otto). Doze diferentes metodologias foram avaliadas, além de técnicas de aprendizagem conjunta que combinam esses diferentes modelos. A avaliação foi realizada a partir do erro de previsão para 3, 6 e 12 meses de projeção. Os testes implementados indicam a superioridade dos modelos propostos frente a um método ingênuo de previsão. Os resultados obtidos mostraram que, para todos os períodos de previsão avaliados, foram encontrados modelos com erro percentual médio inferior a 3%, garantindo uma predição satisfatória.

Palavras-Chave: Combustíveis; Métodos de Previsão; Séries Temporais; Etanol; Gasolina

Abstract

Fuel demand forecast is a fundamental tool which guides private planning actions and investments, besides public policies that aim to guarantee energy supply. In this paper, different forecasting methods were evaluated to project the consumption of light fuels in Brazil (fuels used by vehicles with an internal combustion engine). Twelve different methods were implemented, besides of ensemble learning techniques that combine the different models. The evaluation was carried out based on the forecast error for a forecast horizon of 3, 6 and 12 months. The tests performed indicate the superiority of the evaluated models compared to a naive forecasting method. The results indicate, for all forecast horizon, that it is possible to estimate a model whose mean absolute percentage error is less than 3%, allowing a good level of accuracy.

Keywords: Fuel Demand; Forecasting Methods; Time Series; Ethanol; Gasoline

3.1. INTRODUÇÃO

A estruturação da regulação e da política energética de modo com que haja previsibilidade quanto ao abastecimento contínuo para atendimento da demanda doméstica de um país é essencial tanto do ponto de vista econômico, para melhor alocação de recursos no curto e longo prazo, quanto social, levando em conta os efeitos de uma crise de abastecimento sobre o bem-estar da sociedade.

O gerenciamento da demanda por energia se tornou uma questão mandatória para agentes privados que atuam nessa área, e para o poder público, com o objetivo de planejar a necessidade de recursos futuros, promover medidas de conservação ambiental, otimizar a utilização de recursos e fontes energéticas, auxiliar a tomada de decisão dos agentes e garantir regularidade do suprimento (SUGANTHI; SAMUEL, 2012). Nesse contexto, o uso de modelos quantitativos para realização de previsões é um importante ferramental que auxilia nessa tarefa.

Dentre as diversas fontes de energia, encontra-se os combustíveis líquidos utilizados por veículos a combustão, que ainda são majoritariamente utilizados nos dias de hoje, para atender as necessidades de transporte privado.

No Brasil, o setor de combustíveis líquidos passou por intensas mudanças nos últimos anos em relação as políticas econômicas que definem o funcionamento deste mercado. Fatores tecnológicos, como a presença da frota flexível também contribuem para uma dinâmica mais complexa do mercado brasileiro, uma vez que o consumidor pode, de forma autônoma, alterar entre etanol e gasolina no momento do abastecimento.

Tem-se, portanto, uma série de fatores que tornam difícil e incerta a formação de preços, a dinâmica de produção e, conseqüentemente, a garantia de abastecimento do mercado de combustíveis do ciclo Otto (gasolina, etanol anidro, etanol hidratado e GNV).

Nesse contexto, o objetivo do presente estudo compreende uma avaliação da performance de diversos métodos de previsão usualmente aplicados em abordagens empíricas para previsão de demanda por combustíveis e outras fontes energéticas. Objetiva-se responder: qual a melhor metodologia do ponto de vista de erro de previsão? É satisfatória a performance dos modelos a ponto de utilizá-los como ferramenta de apoio à tomada de decisão? A combinação de modelos acarreta uma melhoria de acurácia relevante?

O tema é de interesse dos agentes privados e de órgãos governamentais, uma vez que a possibilidade de prever de forma satisfatória o consumo futuro dos combustíveis permite melhores decisões quanto ao direcionamento de recursos financeiros e produtivos, um melhor planejamento para garantia do abastecimento energético e, ainda, um dimensionamento do possível impacto ambiental de diferentes composições da matriz energética de combustíveis no Brasil.

Para atender o objetivo proposto, o artigo foi dividido em 5 seções. Além da presente introdução, a próxima seção concentra-se em descrever as principais características do mercado brasileiro de combustíveis e apresentar a revisão de literatura sobre o tema. Em seguida, são descritos os métodos avaliados no presente estudo, sendo estes: Modelos Sarima (SAR) e Arima com variáveis binárias para sazonalidade (SAR.Bin), Vetor Autoregressivo com Mecanismo de Correção de Erro (VECM), Modelo de Decomposição de Séries Temporais por Regressão Local (STL), Modelos Lineares Dinâmicos (DLM), Redes Neurais Artificiais univariadas e multivariadas (ANN e MANN), Máquina de Vetor de Suporte (SVM), Sistema de Inferência Neuro-Fuzzy Híbrido (*Hybrid Neural Fuzzy Inference System* ou HyFIS), *Random Forest* (RF), modelo Grey (GM), modelos híbridos (HM) e, por fim, modelos combinados (*Ensemble*

Learning). No quarto tópico são apresentados nos resultados obtidos e a última seção traz as conclusões do estudo.

3.2. O MERCADO DE COMBUSTÍVEIS BRASILEIRO

O setor de combustíveis leves brasileiro possui algumas peculiaridades derivadas da complexidade tecnológica, produtiva e institucional que afetam, por um lado, as decisões de consumo e, por outro, a dinâmica de produção e abastecimento.

No tocante a tecnologia, a inserção dos veículos flexíveis no início de 2003 deu ao consumidor brasileiro a oportunidade de decidir dentre o etanol e gasolina, ou um mix de ambos no momento do abastecimento. Essa mudança afetou a dinâmica de formação de preços e, conseqüentemente, do próprio consumo de combustíveis do país por tornar mais elástica a demanda pelos combustíveis individualmente (DE FREITAS; KANEKO, 2011).

Quanto a questão produtiva, devido ao fato de a cana-de-açúcar ser a matéria-prima para o etanol brasileiro, a produção do combustível fica sujeita as condições climáticas e aos fundamentos observados no mercado de açúcar. Os ciclos internacionais e flutuações do preço do adoçante afetam as decisões de produção doméstica, uma vez que as usinas podem, ainda que de maneira restrita, optar pela utilização desse insumo compartilhado para um ou outro produto.

O abastecimento interno de gasolina é realizado pelo refino de petróleo por parte da Petrobrás, que possui um quase monopólio da atividade, e pela importação do derivado por outras empresas atuantes na distribuição de combustíveis.

No âmbito institucional, além da já mencionada estrutura concentrada no refino de petróleo, no período de 2008 a 2016 presenciou-se uma constante intervenção governamental no setor para fins de contenção dos efeitos da crise financeira mundial. As principais políticas foram o congelamento do preço da gasolina praticados domesticamente pela Petrobrás e as desonerações de tributos federais sobre o derivado.

Após a imersão em uma crise econômica que levou ao sucateamento das empresas do setor sucroenergético e das contas públicas nacionais, o governo federal passou a tributar novamente os combustíveis para fins de arrecadação tributária e contenção do *déficit* público. Ao mesmo tempo, a política de precificação da Petrobrás foi alterada e o preço da gasolina passou a ser reajustado periodicamente após a empresa sofrer grandes perdas financeiras (RODRIGUES; RODRIGUES, 2018).

Um novo marco para o setor de combustíveis veio pela aprovação da Lei nº 13.576 de dezembro de 2017, a qual instituiu a Política Nacional de Biocombustíveis no Brasil,

RenovaBio⁶. O referido Programa entrou em vigor a partir do final de 2019. Além da grande importância ambiental, a proposta marca uma mudança nas diretrizes da matriz energética de combustíveis de longo prazo no Brasil, estabelecendo metas de emissões de gases de efeito estufa que implicam na mudança dos padrões de consumo atuais para viabilizá-las. Para 2030, as metas já estabelecidas preveem a necessidade de expansão da produção de etanol dos atuais 30 bilhões de litros para cerca de 50 bilhões de litros (CRBIO, 2020; CNPE, 2020).

Nesse contexto, o dimensionamento do consumo doméstico por combustíveis para fins de segurança de abastecimento e, ainda, cumprimentos das metas estabelecidas pelo RenovaBio torna-se essencial para o gerenciamento de recursos tanto por parte do setor público (necessidade de fiscalização, infraestrutura para escoamento da produção, etc.) quanto para o setor privado (aumento da capacidade produtiva, decisão do mix das usinas e, agora, decisão do mix das distribuidoras).

Nesse contexto, alguns estudos se propuseram a formulação de modelos que podem auxiliar essa tarefa. A Tabela 7 apresenta uma amostra de trabalhos cujo objetivo foi estimar a demanda por um ou mais combustíveis líquidos, resumindo as variáveis dependentes, o local em que o estudo foi realizado, a metodologia e variáveis explicativas adotadas.

Tabela 7: Estudos que estimaram a demanda por combustíveis no Brasil e no mundo.

Autores	Local	Método	Variável dependente	Variáveis explicativas
Nasr, Badr e Joun (2003)	Líbano	ANN e Multivariate ANN	Consumo de Gasolina	Preço da gasolina, frota de carros registrados e defasagens da série
Zanini, Souza e Pedreira (2001)	Brasil	Modelo híbrido com redes neurais e regressão dinâmica	Consumo de Gasolina	Preço da gasolina, renda e defasagens da série
Burnquist e Bacchi (2000)	Brasil	Modelo de cointegração (VECM)	Consumo de Gasolina	Preço da gasolina, renda e defasagens da série
Moreira (1996)	Brasil	Modelo de co-integração (VECM)	Consumo de Óleo Diesel	PIB per capita e preço do óleo
Figueira e Burnquist (2006)	EUA	Modelos Box e Jenkins (Sarima)	Consumo de Gasolina	Defasagens da série
Castro (2012)	Brasil	Modelo de cointegração (VECM)	Consumo de Etanol e Gasolina	Preço dos combustíveis e dimensão da frota
Santiago, De Mattos e Perobelli (2011)	Brasil	Modelo híbrido com cointegração (VECM) e insumo-produto	Consumo de gasolina, óleo diesel, óleo	Variáveis macroeconômicas

⁶ O programa tem por objetivo estabelecer metas de emissões para as distribuidoras de combustíveis tendo em vista o nível de poluição relativa a cada combustível. De forma semelhante ao programa norte-americano *Renewable Fuel Standard* o atingimento das metas deverá ser realizado pela compra de títulos de valores mobiliários em uma espécie de mercado de créditos de carbono.

			combustível e etanol	
Johansson e Schipper (1997)	Países da OCDE	Regressão com dados em painel utilizando efeitos fixos e aleatórios	Consumo de gasolina, diesel, gás liquefeito de petróleo e gás natural comprimido	Preço dos combustíveis, renda, impostos sobre combustíveis, densidade populacional e frota de carros estimada.
Al-Ghandoor <i>et al.</i> (2009)	Jordan	Regressão multivariada	Consumo de combustíveis fósseis e energia elétrica	Preço dos combustíveis e energia elétrica, renda, população e condições climáticas
Smith, Hall e Mabey (1995)	Países da OCDE	Modelo de cointegração (VEC) com adaptação para endogeneizar o progresso técnico	Consumo de combustíveis fósseis	Defasagens da série
Ediger e Akar (2007)	Turquia	Modelos Box e Jenkins (Sarima)	Consumo de combustíveis fósseis e outras fontes energéticas	Defasagens da série
Ediger, Akar e Ugurlu (2006)	Turquia	Modelos Box e Jenkins (Sarima) e regressão simples	Consumo de combustíveis fósseis	Defasagens da série
Mu <i>et al.</i> (2004)	China	Modelos de regressão	Consumo de biocombustíveis de áreas rurais	Renda, população da área de plantio e nível educacional.
Islas, Manzini e Masera (2006)	México	Long-range energy alternatives planning system (LEAP) model	Consumo de combustíveis e biocombustíveis	População, PIB, demanda por energia elétrica e fontes disponíveis para transformação em energia
Melikoglu (2014)	Turquia	Modelos semi-empíricos	Consumo de gasolina, diesel, biodiesel, etanol e gás liquefeito de petróleo.	Variável de tempo

Os estudos realizados para o mercado brasileiro limitam-se nos seguintes aspectos: i) são essencialmente concentrados no uso de metodologias tradicionais de séries temporais; ii) não tem o foco em verificar se é possível estimar um modelo acurado para a previsão de consumo de combustíveis leves (no geral, o foco está em verificar o encaixe do modelo nos dados de treinamento e a significância das elasticidades); iii) não testam de forma dinâmica diversas metodologias em uma mesma base de dados e com uma mesma métrica de erro buscando de avaliar qual delas se mostra superior no ajuste do modelo e na previsão.

Em síntese, os trabalhos apresentados na Tabela 7 não se dedicaram à realização de previsões para o consumo de combustíveis leves. Em verdade, a maior parte desses estudos buscou estimar equações de demanda por combustíveis para a construção de cenários a partir das variáveis explicativas inseridas nos modelos adotados.

As variáveis explicativas mais usuais na literatura consistem em renda e preços dos combustíveis. É importante destacar que em modelos cujo objetivo é a previsão, deve-se ponderar a inclusão de novas variáveis explicativas uma vez que isso incorrerá no carregamento dos erros de previsão destas para a previsão da variável dependente, não garantindo maior acurácia desses modelos (HYNDMAN; ATHANASOPOULOS, 2018).

Nesse contexto, existe na literatura inúmeros trabalhos que se propuseram a modelar e projetar a demanda por energia elétrica. Além de ser um campo correlato ao consumo energético de combustíveis leves, as séries adotadas nessas pesquisas se assemelham àquela utilizada no presente trabalho. Desse modo, esses estudos podem oferecer indicações importantes dos modelos avaliados nesta pesquisa.

Na revisão desses trabalhos, as seguintes técnicas de projeção foram mais recorrentes: modelos de Lógica Fuzzy (CHANG; FAN; LIN, 2011; KUCUKALI; BARIS, 2010; PADMAKUMARI; MOHANDAS; THIRUVENGADAM, 1999; PAI, 2006), Máquina de Vetores de Suporte (AHMAD *et al.*, 2014; CHE; WANG, 2014; CHEN *et al.*, 2017; DEBNATH; MOURSHED, 2018; FAN; CHEN; LEE, 2008; GARCÍA NIETO *et al.*, 2018; HONG, 2009), Random Forest (DUDEK, 2015; IBARRA-BERASTEGI *et al.*, 2015; LAHOUAR; BEN HADJ SLAMA, 2015; M.J. *et al.*, 2014) e modelos híbridos (BABU; REDDY, 2014; BARAK; SADEGH, 2016; MAIA; DE CARVALHO; LUDERMIR, 2008; NENGLING; STENZEL; HONGXIAO, 2006; NIE *et al.*, 2011; WEI; CHEN; LEE, 2013).

Embora pouco exploradas para previsão do consumo de combustíveis os modelos Grey (AKAY; ATAK, 2007; HAMZACEBI; ES, 2014; PAO; TSAI, 2011) e de Redes Neurais Artificiais (EBRAHIMPOUR *et al.*, 2011; KADIR KAVAKLIOGLU, HALIM CEYLAN, HARUN KEMAL OZTURK, 2009; KANDANANOND, 2011; KHASHEI; BIJARI, 2010; RINGWOOD; BOFELLI; MURRAY, 2001; SÖZEN; ARCAKLIOĞLU; ÖZKAYMAK, 2005; XIA; WANG; MCMENEMY, 2010) têm sido recorrentemente adotados para a previsão da demanda de diversas fontes energéticas e outras aplicações. Outras metodologias aplicadas à previsão de demanda e produção de diversas fontes energéticas podem ser consultadas em Deb *et al.*, (2017), Debnath e Mourshed (2018) e Suganthi e Samuel (2012).

3.3. MÉTODOS DE PREVISÃO UTILIZADOS NO ESTUDO

Os tópicos a seguir têm por objetivo apresentar os modelos testados no presente estudo. Inicialmente são detalhados os procedimentos prévios para tratamento dos dados e seleção de hiperparâmetros dos modelos. Em seguida, cada seção concentra-se em destacar a forma de estimação dos parâmetros, os testes de diagnóstico, as principais vantagens e desvantagens de

cada método e as referências metodológicas adotadas. Por fim, são apresentados os critérios de avaliação e comparação empregados nesse estudo.

3.3.1. Fonte de dados e pré-tratamento

A base de dados utilizada é composta pela soma do consumo de gasolina, etanol anidro, etanol hidratado e GNV convertidos em litros de gasolina equivalente, baseada na eficiência energética de cada combustível. Essa conversão é necessária para considerar os rendimentos distintos de cada combustível na composição da demanda (RODRIGUES; BACCHI, 2017). Os dados foram retirados de ANP (2019). A série, que se inicia em janeiro de 2002 e se encerra em agosto de 2018, pode ser visualizada na Figura 11.




Figura 11: Consumo de Etanol Hidratado, Gasolina e GNV em litros de gasolina equivalente mensais do período de agosto de 2002 a agosto de 2018.

Para o modelo de cointegração e ANN multivariado, outras duas séries foram tomadas como endógenas e projetadas em conjunto ao consumo do ciclo Otto. A primeira consiste no PIB *per capita* estimado a partir do PIB mensal divulgado pelo BACEN (2019) e da população residente pelo IBGE (2019). A segunda, por sua vez, refere-se ao preço médio dos combustíveis leves ao consumidor final (ANP, 2019) como uma *proxy* do preço médio pago pelo consumo de combustíveis do ciclo Otto.

O procedimento adotado para a definição da demanda energética por combustíveis leves (variável dependente) e para o cálculo do preço médio dos combustíveis do ciclo Otto segue a mesma proposta adotada por Rodrigues e Bacchi (2016).

3.3.2. Determinação de hiperparâmetros dos modelos

Cada modelo possui um conjunto de hiperparâmetros que deve ser determinado *a priori* e outro conjunto de parâmetros estimados por um processo de otimização pautada em algum procedimento estatístico paramétrico ou não-paramétrico. A Tabela 8 apresenta os hiperparâmetros de cada modelo.

Tabela 8: Hiperparâmetros a serem determinados *a priori* em cada modelo.

Modelo	Hiperparâmetros
Sarima	Número de termos autoregressivos (p), médias móveis (q), ordem de integração (d), número de termos autoregressivos sazonais (P), médias móveis sazonais (Q) e ordem de integração sazonal (D).
Arima c / Binárias	Número de termos autoregressivos (p), médias móveis (q), ordem de integração (d)
VECM	Número de termos autoregressivos (p) e vetores de cointegração (r).
Modelo Estrutural	Fator de desconto para estimação das matrizes de covariâncias (δ).
STL	Número de passagens pelo <i>loop</i> interno $n_{(i)}$, número de iterações do <i>loop</i> externo $n_{(o)}$, parâmetros que suavizam o componente de baixa frequência presente no componente sazonal $n_{(l)}$ e d_l , parâmetros que suavizam o componente de tendência $n_{(T)}$ e d_T , parâmetros que suavizam o componente sazonal $n_{(s)}$ e d_s .
ANN	Número de termos autoregressivos (p), número de neurônios na primeira e segunda camada oculta (k_1, k_2).
Multi ANN	Número de termos autoregressivos (p) das variáveis de saída, i.e, consumo ciclo Otto, preço médio dos combustíveis e PIB <i>per capita</i> , número de neurônios na primeira e segunda camada oculta (k_1, k_2).
SVM	Número de termos autoregressivos (p), erro insensível (ϵ), constante C e o kernel para transformação do espaço de entrada no espaço de características.
Hyfis	Número de termos autoregressivos (p), número de características do universo de discurso (L).
Random Forest	Número de termos autoregressivos (p), número de árvores (B), número de variáveis explicativas utilizadas por árvore (m) e número mínimo de observações em um nó terminal (n_{min}^B).
Grey Model	Número de observações mais recentes utilizadas para estimação do modelo (n) e o coeficiente de ajuste (θ).
Modelos Híbridos	Número de termos autoregressivos (p_L), médias móveis (q) e ordem de integração (d) do modelo da componente linear e número de termos autoregressivos (p_{NL}), erro insensível (ϵ), constante C e o kernel para transformação do espaço de entrada no espaço de características do modelo da componente não linear.

O erro de treinamento pode ser reduzido infinitamente conforme o modelo aumenta sua complexidade (i.e., o número de parâmetros e a forma com que as variáveis se relacionam), no entanto, tais modelos sofrerão problemas de super-encaixe (*overfitting*) e a generalização poderá ocorrer de forma precária. Assim, a determinação de um conjunto de hiperparâmetros

de um modelo deve ocorrer pela minimização da estimativa do erro de generalização, ou erro de previsão (HASTIE *et al.*, 2009).

Para modelos lineares em seus parâmetros, uma forma simples de avaliar a capacidade de generalização consiste na comparação dos critérios de informação de Akaike (AIC) ou Bayesiano (BIC) (HASTIE *et al.*, 2009; HYNDMAN; ATHANASOPOULOS, 2018). Esses são os casos dos modelos Sarima, VECM (os quais ainda possuem outros procedimentos descritos nas próximas sessões) e STL. No presente estudo, o critério utilizado foi o AIC.

No entanto, quando se trata de modelos não-lineares, recorre-se a formas empíricas de estimação do erro de generalização. A forma mais comum é a validação cruzada (HASTIE *et al.*, 2009; KUHN; JOHNSON, 2013).

A validação cruzada envolvendo séries temporais é diferente dos problemas envolvendo dados em painel devido a dinâmica autoregressiva da série (BERGMEIR; HYNDMAN; KOO, 2018; HYNDMAN; ATHANASOPOULOS, 2018). No presente estudo, seguindo lógica semelhante a proposta por Hyndman e Athanasopoulos (2018), o procedimento foi estruturado da seguinte forma:

1. Um conjunto de parâmetros α_i é selecionado inicialmente para o modelo.
2. Um corte inicial é realizado na série de consumo de ciclo Otto restando apenas os dados de janeiro de 2002 a dezembro de 2011, i.e, 120 observações do total de 200. A escolha desse ponto de corte se deve a mudança de tendência na série percebida a partir de 2013.
3. Essa subsérie é utilizada para estimativa dos modelos e realização das previsões (\hat{Y}) h passos-à-frente e o vetor de erro das previsões é calculado e armazenado.
4. Uma nova observação é adicionada na base de treino e o passo 3 é repetido.
5. Os passos 3 e 4 são repetidos até que a previsão h passos-à-frente tenha como último período previsto a última observação conhecida da série. Assim, o passo 3 e 4 são realizados $81 - h$ vezes e este mesmo número de vetores de erros são gerados, cada um contendo h erros de previsão. A raiz quadrada do erro quadrático médio (RMSE) é calculado para o modelo com parâmetros α_i conforme a Eq. (9).

$$RMSE_i = \sqrt{\frac{1}{(81 - h)h} \sum_{j=1}^{(81-h)h} (Y_j - \hat{Y}_j)^2} \quad (9)$$

Com os erros de previsão de todas as subséries obtidas, é possível estimar métricas de erro de generalização do modelo e selecionar aquele com melhor desempenho. Esse procedimento foi realizado e a melhor estrutura foi selecionada para previsões de 3, 6 e 12

meses para avaliar a performance em horizontes de curto, médio e longo prazos. Esse procedimento iterativo, além de evitar o super-encaixe será utilizado como base para comparação dos algoritmos, conforme será descrito da seção 3.3.14.

Os trabalhos de Nelson *et al.* (1999) e Zhang e QI (2005) concluíram que alguns algoritmos podem apresentar dificuldades no tratamento de séries sazonais. Assim, visando evitar essa complicação, três diferentes formas de tratamento da sazonalidade são avaliadas. Na primeira, a série dessazonalizada é utilizada para treinamento do modelo, sendo a dessazonalização realizada por meio de um filtro de médias móveis. Nas duas últimas abordagens, a modelagem e a previsão do componente sazonal são realizadas pelo próprio modelo, seja pela inclusão de um termo autoregressivo sazonal ou pela inclusão de regressores binários para cada um dos meses.

A mesma lógica é válida para o pré-tratamento dos dados exigido por alguns algoritmos. Nesses casos, as formas de pré-processamento exigem a padronização dos dados pela média e desvio-padrão ou em logaritmo para realizar o treinamento dos modelos.

A definição do pré-processamento a ser adotado, bem como da forma de tratamento da sazonalidade de dados para os modelos ANN, SVM, HyFis e *Random Forest* foi estabelecida a partir do procedimento de validação cruzada.

3.3.3. Modelo Sazonal Autoregressivo Integrado com Médias Móveis (Sarima)

O modelo Sarima $(p,d,q)(P,D,Q)$ (SAR) é um método muito popular de modelagem paramétrica. A ideia central consiste em ajustar um modelo capaz de explicar uma série temporal estacionária por meio dos valores passados da própria série e dos erros do modelo (BOX; JENKINS; REINSEL, 2008).

A estimação se dá, primeiramente, pela determinação dos parâmetros p, q, d, P, Q e D que representam o número de defasagens, o número de médias móveis, a ordem de integração, o número de defasagens sazonais, o número de média móveis sazonais e a ordem de integração sazonal. O modelo estimado pode ser representado conforme a Eq. (10).

$$\begin{aligned} \Delta^D(\Delta^d N_t) = \phi_0 + \sum_{i=1}^p \phi_i \Delta^D(\Delta^d N_{t-i}) + \sum_{i=1}^q \theta_i e_{t-i} \\ + \sum_{j=1}^P \Phi_j \Delta^D(\Delta^d N_{t-f \times j}) + \sum_{j=1}^Q \Theta_j e_{t-f \times j} + e_t, t = 1, \dots, n \end{aligned} \quad (10)$$

Em que Δ^d e Δ^D é o operador de diferenciação de ordem d e D respectivamente, ϕ_0 é o intercepto da série estacionária e ϕ_i, θ_i, Φ_j e Θ_j são coeficientes que multiplicam os termos autoregressivos e de médias móveis, e f é a frequência da série que caracteriza sua sazonalidade

(para uma série mensal $f = 12$), e_t é um erro normalmente distribuído com média zero e variância σ_e^2 .

Além da abordagem tradicional, que utiliza as próprias defasagens da série e dos erros para incorporação dos efeitos da sazonalidade, este estudo propõe uma abordagem alternativa utilizando regressores binários (SAR.Bin). Desse modo, o modelo passa a ser representado pela Eq. (11).

$$\Delta^D(\Delta^d N_t) = \phi_0 + \sum_{i=1}^p \phi_i \Delta^D(\Delta^d N_{t-i}) + \sum_{i=1}^q \theta_i e_{t-i} + \sum_{m=1}^{f-1} \beta_m b_m + e_t, t = 1, \dots, n \quad (11)$$

Apenas $f - 1$ variáveis são incluídas no modelo visando preservar o intercepto e não gerar multicolineariedade perfeita. Nesse caso, b_m é a variável binária que representa um mês m e β_m é o coeficiente que retrata o efeito diferencial desse mês em relação a um mês base. O efeito da sazonalidade no mês base é dado por ϕ_0 , enquanto para qualquer $m = 1, \dots, f - 1$ este efeito será $\phi_0 + \beta_m$.

Para determinação de p , q , P e Q é comum a utilização das funções de autocorrelação e autocorrelação parcial. As ordens de integração estão ligadas a estacionariedade da série e podem ser determinadas de forma visual, pelo gráfico da série, pelas funções de autocorrelação e por meio de testes de raiz unitária. Neste estudo, foram realizados os testes KPSS (KWIATKOWSKI *et al.*, 1992), DF-GLS (ELLIOTT; ROTHENBERG; STOCK, 1996) para uma raiz, o teste DP (DICKEY; PANTULA, 1987) para duas raízes, e os testes de raiz unitária sazonal proposto por Osborn *et al.* (1988).

Os procedimentos anteriores não garantem unicidade do modelo ótimo. A seleção final se baseia no critério de informação AIC, tomando o modelo com menor valor, e que resulte em resíduos que sejam ruídos brancos (HYNDMAN; ATHANASOPOULOS, 2018). Os testes de autocorrelação de Ljung-Box, ARCH-LM para heterocedasticidade e o teste de Jarque-Bera (BUENO, 2018) e Shapiro-Wilk (SHAPIRO; WILK, 1965) para a normalidade foram implementados na verificação dos modelos. O Apêndice 1 apresenta os resultados dos testes estatísticos realizados.

Com exceção dos testes de normalidade dos resíduos, os diagnósticos realizados demonstram boa aderência do modelo Sarima. O Arima com variáveis binárias selecionado, conforme os critérios mencionados, apresenta problemas de heterocedasticia. Os testes de normalidade, de forma geral, apresentam baixo poder e grande sensibilidade a presença de

outliers e, nesses casos, costumam rejeitar a hipótese de dados normalmente distribuídos com facilidade (COIN, 2008).

As Figuras 12 e 13 apresentam uma análise gráfica comparando os quartis dos resíduos amostrais com os quartis teóricos de uma distribuição normal. A linha sólida representa os pontos em que o quartil amostral seria igual ao quartil teórico. Embora a série tenha grande aderência, algumas observações extremas se afastam do valor teórico e distorcem os testes.




Figura 12: Comparação dos quartis amostrais com os quartis teóricos para os resíduos do modelo Sarima de consumo de ciclo otto.




Figura 13: Comparação dos quartis amostrais com os quartis teóricos para os resíduos do modelo Arima com variáveis binárias de consumo de ciclo otto.

Embora o Sarima tenha obtido desempenho superior nos testes de verificação, ambas as abordagens foram consideradas nos procedimentos de comparação de modelos, visto o objetivo do estudo de comparar metodologias sob o critério da melhor previsão dos dados.

3.3.4. Vetor Autoregressivo com Mecanismo de Correção de Erro (VECM)

O Vetor Autoregressivo com Mecanismo de Correção de Erro (VECM) consiste em uma abordagem alternativa para previsão de séries temporais não estacionárias. A princípio, o intuito da metodologia consiste na identificação da trajetória de uma série dado um choque estrutural, isto é, como uma mudança em uma das variáveis endógenas afetam o curso das outras variáveis endógenas do modelo. Um vetor autoregressivo (VAR) consiste em um modelo de m variáveis endógenas com comportamento autoregressivo multivariado de ordem p que pode ser expresso conforme a Eq. (12).

$$\mathbf{Y}_t = \Phi_0 + \sum_{i=1}^p \Phi_i \mathbf{Y}_{t-i} + \mathbf{GZ}_t + \mathbf{e}_t, t = 1, \dots, n \quad (12)$$

Em que \mathbf{Y}_t e \mathbf{e}_t são vetores de m variáveis endógenas e ruídos brancos, \mathbf{Z}_t é um vetor de g variáveis exógenas, os vetores de coeficientes Φ_0 e $\Phi_i, i = 1, \dots, p$ de comprimento m e \mathbf{G} é a matriz de coeficientes das variáveis exógenas de dimensão $m \times g$.

Para se estimar um modelo VAR é necessário que todas as variáveis endógenas sejam estacionárias (LÜTKEPOHL, 2005). Quando essas variáveis são não estacionárias, i.e integradas de ordem d ou $I(d)$, mas possuem uma trajetória comum de longo prazo, ainda é possível utilizar um VAR introduzindo um termo chamado vetor de correção de erros que estabilizam o sistema.

Quando existe um equilíbrio de longo prazo, as variáveis contidas em \mathbf{Y}_t são ditas cointegradas de ordem (d, b) ou $C(d, b)$. Nesse caso, existe pelo menos um vetor β não nulo, chamado de vetor de cointegração, tal que $u_t = \beta^T \mathbf{Y}_t$ seja $I(d - b), b > 0$, em que u_t é uma série resultante da combinação linear de \mathbf{Y}_t .

Para que exista uma representação de \mathbf{Y}_t na forma de um VECM é necessário que $u_t \sim I(0)$, ou seja, que exista uma combinação linear do vetor \mathbf{Y}_t com pesos β que gere uma série estacionária.

Pode-se estimar até $m - 1$ vetores de cointegração e correção de erro pelo resíduo das regressões entre as variáveis armazenadas em \mathbf{Y}_t . Caso essas condições sejam atendidas, a Eq. (12) poderá ser alterada e \mathbf{Y}_t poderá ser expresso por um modelo VECM conforme a Eq. (13).

$$\Delta \mathbf{Y}_t = \alpha \mathbf{B}^T \mathbf{Y}_{t-1} + \sum_{j=1}^{p-1} \Pi_j \Delta \mathbf{Y}_{t-j} + \mathbf{GZ}_t + \mathbf{e}_t \quad (13)$$

Em que $\mathbf{B} = [\boldsymbol{\beta}_1, \boldsymbol{\beta}_2, \dots, \boldsymbol{\beta}_r]$ e $\boldsymbol{\alpha}$ são matrizes $m \times r$ tal que $r = \text{posto}(\boldsymbol{\alpha}\boldsymbol{\beta}^T)$, $r < m$ é o número de vetores de cointegração não nulos e, conseqüentemente, de vetores de correção de erro. Estes últimos estão expressos por $\mathbf{B}^T \mathbf{Y}_{t-1} = \mathbf{u}_{t-1} = [u_{t-1}^1, u_{t-1}^2, \dots, u_{t-1}^r]$ e $\Pi_j = -\sum_{i=1+j}^{p-1} \Phi_i$, $j = 1, \dots, p-1$ são vetores de coeficientes que multiplicam $\Delta \mathbf{Y}_{t-j}$.

O teste de cointegração entre as variáveis e a estimativa dos parâmetros do modelo foi conduzido conforme proposto por Johansen (1988, 1991). O teste de máximo autovalor foi utilizado para determinação de r . A estimativa das matrizes de coeficientes foi realizada pelo método da máxima verossimilhança. A seleção do número de termos autoregressivos foi baseada nos critérios de informação AIC, assim como no Sarima, tomando o modelo com menor valor e que resulte em vetores de resíduos que sejam ruído branco.

No processo de verificação dos modelos, os testes para autocorrelação de Portmanteau (LÜTKEPOHL, 2005) e de Edgerton e Shukur (1999), o teste de normalidade multivariada de Jarque-Bera (LÜTKEPOHL, 2005) e Shapiro-Wilk (SHAPIRO; WILK, 1965) e o teste de heterocedasticia multivariada (ENGLE, 1982) dos resíduos ARCH-LM foram realizados. O Apêndice 2 apresenta os resultados dos testes estatísticos realizados.

Do mesmo modo que no modelo Sarima, os testes de diagnóstico corroboram para conclusão de que o modelo possui um bom ajuste aos dados, com exceção do teste de normalidade dos resíduos. As Figuras 14 a 16 apresentam uma análise gráfica dos quantis amostrais e teóricos dos resíduos de cada série utilizada no VECM. O motivo da rejeição da normalidade pelo teste e conclusões derivadas da análise gráfica também não são diferentes do que foi apresentado anteriormente. O Apêndice 2 apresenta a distribuição dos resíduos estimados do modelo VECM comparada com uma distribuição normal teórica.

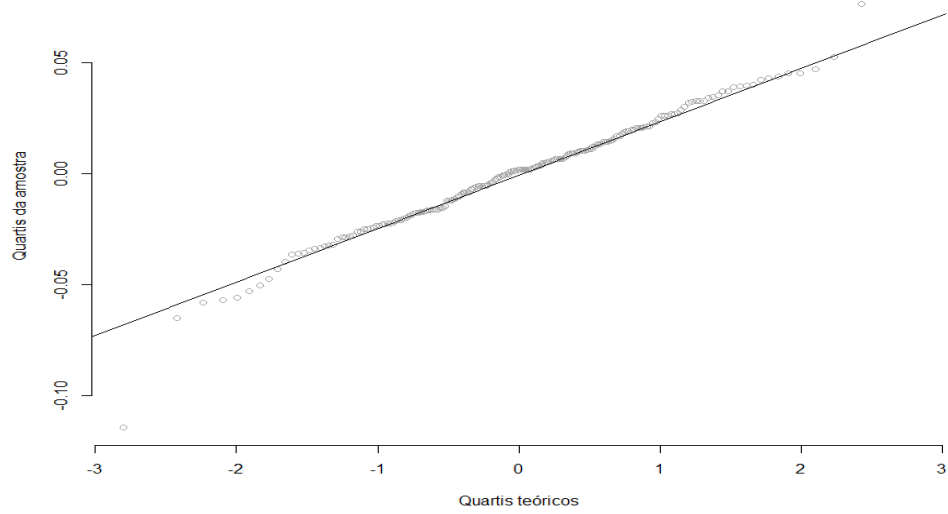


Figura 14: Comparação dos quartis amostrais com os quartis teóricos para os resíduos do modelo VECM para a série de consumo de ciclo otto.




Figura 15: Comparação dos quartis amostrais com os quartis teóricos para os resíduos do modelo VECM para a série de preço médio do ciclo otto.




Figura 16: Comparação dos quartis amostrais com os quartis teóricos para os resíduos do modelo VECM para a série de PIB per capita.

3.3.5. Modelos Lineares Dinâmicos (Modelo Estrutural)

Um modelo linear dinâmico (DLM) é um caso especial dos modelos de espaço-estado. Neste último, as variáveis dependentes são resultado de um sistema dinâmico perturbado por um erro aleatório em seu estado. Os problemas de estimação e previsão são resolvidos computando recursivamente a distribuição *a posteriori* das variáveis de interesse dada a informação disponível. Nesse sentido, os modelos são tratados segundo uma abordagem bayesiana (PETRIS; PETRONE, 2011; WEST; HARRISON, 1997).

Em um DLM, os parâmetros a serem estimados possuem distribuição *a priori* normal e as relações guardadas com a variável dependente são lineares. A representação geral do modelo é dada pelas equações 14 e 15.

$$\mathbf{Y}_t = \mathbf{F}_t \boldsymbol{\theta}_t + \mathbf{v}_t \quad \mathbf{v}_t \sim N_m \left(0, \mathbf{V}_{t(m \times m)} \right) \quad (14)$$

$$\boldsymbol{\theta}_t = \mathbf{G}_t \boldsymbol{\theta}_{t-1} + \mathbf{w}_t \quad \mathbf{w}_t \sim N_p \left(0, \mathbf{W}_{t(p \times p)} \right) \quad (15)$$

Em que \mathbf{Y}_t é um vetor de observações de m variáveis dependentes, \mathbf{F}_t e \mathbf{G}_t são matrizes conhecidas de dimensão $m \times p$ e $p \times p$, respectivamente. \mathbf{v}_t e \mathbf{w}_t são vetores de erros gaussianos de dimensão m e p , $\boldsymbol{\theta}_t$ é um vetor p -variado de parâmetros de estado não correlacionados com os erros de ambas as equações.

A Eq. (14) é chamada equação de observação, enquanto a Eq. (15) é denominada de equação de estado ou equação de sistema. Quando o conjunto $\{\mathbf{F}_t, \mathbf{G}_t, \mathbf{V}_t, \mathbf{W}_t\}$ é constante para todo t o modelo é chamado DLM constante.

Um caso específico dos DLM constantes é chamado modelo estrutural para séries temporais. Neste caso, a série é decomposta em termos da sua tendência, sazonalidade, componente cíclico e aleatório. Deste modo, o modelo não só fornece base para realizar previsões de valores futuros da série como também provê uma descrição das características das séries de tempo (HARVEY, A. C.; PETERS, 1990; HARVEY, ANDREW C., 1990; HARVEY, ANDREW C.; SHEPHARD, 1993).

A Eq. (16) apresenta a composição multiplicativa assumida neste estudo para a série de consumo de ciclo Otto. Assim, no momento t , o valor de Y_t pode ser decomposto nos componentes de tendência (T_t), sazonalidade (S_t) e componente aleatório (ϵ_t).

$$Y_t = T_t \times S_t \times \epsilon_t \quad (16)$$

Para a estimação foi assumido componente de tendência na forma linear enquanto o efeito da sazonalidade foi captado por variáveis binárias. Os dados foram transformados em logaritmos para que uma decomposição aditiva de Y_t fosse obtida. A forma funcional da equação de observação é dada pela Eq. (17).

$$\log Y_t = \mu + \beta t + \sum_j^{f-1} \gamma_j d_j + e_t \quad (17)$$

Em que f é a frequência da série e $e_t = \log \epsilon_t$. Este modelo pode ser estruturado no formato das equações 18 e 19 e a inferência dos parâmetros pode ocorrer utilizando o filtro de Kalman desde que duas condições sejam atendidas (WEST; HARRISON, 1997): i) O vetor de parâmetros $\theta_t = \{\mu, \beta, \gamma\}$ sigam uma cadeia de markov, i.e, $\Pr(\theta_t | \mathbf{Y} = \{Y_t\}_{t=1}^n) = \Pr(\theta_t | \{\theta_t\}_{t=1}^n) = \Pr(\theta_t | \theta_{t-1})$ e ii) Condicionalmente a θ_t , \mathbf{Y} é i.i.d para todo t e Y_t depende apenas de θ_t .

$$\log Y_t = [1 \ 0 \ 1 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0 \ 0] \theta_t + v_t \quad (18)$$

$$\theta_t = \begin{bmatrix} \mu_t \\ \beta_t \\ \gamma_{1t} \\ \gamma_{2t} \\ \gamma_{3t} \\ \gamma_{4t} \\ \gamma_{5t} \\ \gamma_{6t} \\ \gamma_{7t} \\ \gamma_{8t} \\ \gamma_{9t} \\ \gamma_{10t} \\ \gamma_{11t} \end{bmatrix} = \begin{bmatrix} 1 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 & -1 \\ 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 0 & 1 & 0 & 0 \end{bmatrix} \begin{bmatrix} \mu_{t-1} \\ \beta_{t-1} \\ \gamma_{1t-1} \\ \gamma_{2t-1} \\ \gamma_{3t-1} \\ \gamma_{4t-1} \\ \gamma_{5t-1} \\ \gamma_{6t-1} \\ \gamma_{7t-1} \\ \gamma_{8t-1} \\ \gamma_{9t-1} \\ \gamma_{10t-1} \\ \gamma_{11t-1} \end{bmatrix} + \begin{bmatrix} w_{1t} \\ w_{2t} \\ w_{3t} \\ w_{4t} \\ w_{5t} \\ w_{6t} \\ w_{7t} \\ w_{8t} \\ w_{9t} \\ w_{10t} \\ w_{11t} \\ w_{12t} \\ w_{13t} \end{bmatrix} \quad (19)$$

Os parâmetros foram estimados utilizando um procedimento de inferência bayesiana conjugada proposta por West e Harrison (1997), o qual adapta a estimação padrão executada por meio do filtro de Kalman introduzindo um mecanismo de fatores de desconto para estimação das matrizes de covariâncias dos ruídos \mathbf{V}_t e \mathbf{W}_t . A determinação do fator de desconto foi realizada utilizando o procedimento de validação cruzada descrito na seção 3.3.14. pois, embora o modelo seja linear nos coeficientes da equação de previsão, ele não é linear em relação ao fator de desconto.

3.3.6. Modelo de Decomposição de Séries Temporais por Regressão Local (STL)

O procedimento de decomposição STL (*Seasonal-Trend Decomposition Procedure Based on Loess*) foi desenvolvido por Cleveland *et al.* (1990) e tem o objetivo de decompor uma série temporal (Y_t) em três componentes: tendência (T_t), sazonalidade (S_t) e resíduo (ϵ_t). Assume-se que a decomposição da série é aditiva conforme a Eq. (20).

$$Y_t = T_t + S_t + \epsilon_t \quad (20)$$

Para obtenção de uma decomposição multiplicativa, pode-se tomar o logaritmo da série antes da implementação do método (HYNDMAN; ATHANASOPOULOS, 2018).

O STL parte de uma condição inicial arbitrária para os componentes da série e por meio de regressões locais as estimam iterativamente. De acordo com Cleveland *et al.* (1990), o procedimento de obtenção dos componentes em uma interação $k + 1$ a partir dos valores estimados em k consistem em:

1. Obter a série sem tendência, ou a série de ciclos, $Y_t - T_t^k$ para $t = 1, \dots, n$.
2. Suavizar por regressão local a série sem tendência para cada subsérie separadamente, utilizando $n_{(s)}$ vizinhos mais próximos e um polinômio de grau d_s obtendo a série suavizada C_t^{k+1} para $t = 1, \dots, n$.
3. Aplicar um filtro de médias móveis com comprimento $n_{(p)}$ em C_t^{k+1} e em seguida uma suavização por regressão local com os $n_{(l)}$ vizinhos mais próximos e um polinômio de grau d_l para obter L_t^{k+1} para $t = 1, \dots, n$.
4. O componente sazonal é obtido fazendo $S_t^{k+1} = C_t^{k+1} - L_t^{k+1}$ para $t = 1, \dots, n$.
5. Realizar a dessazonalização da série original fazendo $Y_t - S_t^{k+1}$ para $t = 1, \dots, n$.
6. A série dessazonalizada é então suavizada por regressão local considerando os $n_{(T)}$ vizinhos mais próximos e um polinômio de grau d_T . O resultado dessa suavização consiste no componente de tendência T_t^{k+1} para $t = 1, \dots, n$.

O procedimento acima é chamado de loop interno e é repetido $n_{(i)}$ vezes. Assume-se que $T_t^0 = 0$. Em seguida, para aumentar a robustez das estimativas o loop externo é realizado utilizando os valores de $T_t^{n_{(i)}}$ e $S_t^{n_{(i)}}$. O seguinte procedimento é executado no loop externo:

1. Obtém-se o componente residual da série fazendo $\epsilon_t = Y_t - T_t^{n_{(i)}} - S_t^{n_{(i)}}$ para $t = 1, \dots, n$.
2. O peso de robustez, ρ_t , é calculado para $t = 1, \dots, n$ conforme a Eq. (21). Outliers na amostra com valores grandes de ϵ_t devem resultar em pesos próximos a zero.

$$\rho_t = \begin{cases} [1 - |\epsilon_t|^2 / (6 \text{ median}(|\epsilon_t|))^2] & \text{para } 0 \leq |\epsilon_t| / (6 \text{ median}(|\epsilon_t|)) \leq 1 \\ 0 & \text{para } |\epsilon_t| / (6 \text{ median}(|\epsilon_t|)) \geq 1 \end{cases} \quad (21)$$

3. O loop interno é então repetido tomando agora T_t^0 como a tendência estimada no último loop interno $T_t^{n_{(i)}}$. Nos passos 2 a 6 o peso das vizinhanças das regressões locais para um valor no tempo t é multiplicado pelo peso de robustez ρ_t .

O loop externo é repetido $n_{(o)}$ vezes. A escolha dos hiperparâmetros apresentados na Tabela 8 é discutida por Cleveland *et al.* (1990). Hyndman e Athanasopoulos (2018) propuseram uma regra de escolha que visa balancear o super-encaixe da sazonalidade, mas permitindo uma mudança pequena ao longo do tempo. Essa sugestão foi utilizada para escolha dos parâmetros. Seguindo essa proposta os parâmetros do processo iterativo foram $n_{(p)} = 12$, $n_{(i)} = 1$, $n_{(o)} = 15$, $n_{(l)} = n_{(s)} = 13$, $n_{(T)} = 21$, $d_l = d_T = 1$, $d_s = 0$.

Para prever uma série de tempo, o STL analisa separadamente o componente sazonal e o componente de tendência. O componente sazonal para um ciclo futuro é obtido assumindo-o igual ao último componente estimado pelo processo anteriormente descrito. A série dessazonalizada é prevista por qualquer método de previsão não sazonal (HYNDMAN; ATHANASOPOULOS, 2018).

Neste caso foi utilizado um modelo ETS, um método que também é baseado na decomposição da série a partir de um modelo de espaço-estado cujos parâmetros são os estados iniciais do nível e tendência (l_0, b_0) e os parâmetros de suavização das equações de estado (α, β) . O nível, a tendência e os erros estocásticos do modelo podem se relacionar de forma aditiva ou multiplicativa. A seleção do melhor modelo foi baseada no critério de informação AIC, que utiliza a função de verossimilhança calculada durante a inferência os parâmetros l_0, b_0, α e β . Para mais detalhes sobre o ETS ver Hyndman *et al.* (2008).

O STL é robusto a *outliers* e capaz de tratar qualquer tipo de sazonalidade, visto que o componente sazonal e de tendência podem se alterar ao longo do tempo e a taxa de mudança pode ser controlada pelo analista por meio dos parâmetros $n_{(T)}$ e $n_{(S)}$.

3.3.7. Redes Neurais Artificiais (ANN)

As Redes Neurais Artificiais (ANN) são modelos baseados na dinâmica de funcionamento do sistema nervoso humano. Assim como uma Rede Neural biológica, as artificiais podem ser representadas por uma rede de elos orientados que são interligados em certos pontos chamados nós ou neurônios (HAYKIN, 2001)

Cada neurônio é representado por um conjunto de variáveis de entrada combinadas linearmente, um *bias* aplicado externamente e um elo que introduz a chamada função de ativação, comumente não-linear. O *bias* é equivalente a um termo constante e pode ser representado por uma entrada fixa em +1. Os elos sinápticos ponderam as variáveis de entrada e a aplicação da função de ativação sobre soma ponderada dessas variáveis definem a resposta do neurônio em questão.

Algebricamente, em uma ANN em que todos os neurônios de uma camada estão interligados com todos os neurônios da camada seguinte (chamada ANN totalmente conectada) a saída de um neurônio k de uma camada l , representada por f_k^l , é dado pela aplicação de uma função de ativação $g(\cdot)$ sobre a combinação linear das saídas dos neurônios pertencentes a camada $l - 1$, i.e, $f_k^l = g(\sum_{k' \in l-1} \omega_{k'}^l f_{k'}^{l-1})$, em que $\omega_{k'}^l$ é o vetor de pesos que ponderam os elos sinápticos dos neurônios k' pertencentes a camada $l - 1$ para o neurônio k da camada l . Cada neurônio de cada camada possui um conjunto de vetor de pesos que ponderam as variáveis de entrada daquele nó.

Seja o vetor de parâmetros do modelo dado por $\boldsymbol{\omega} = \left\{ \left\{ \omega_{k'}^l \right\}_{k' \in l-1} \right\}_{l=1}^L$, $\{\mathbf{Y}_t, \mathbf{x}_t\}_{t=1}^n$ um conjunto de dados conhecidos em que \mathbf{Y}_t é o vetor m -variado de resposta ideal para um vetor p -variado de entrada \mathbf{x}_t . O valor estimado de $\boldsymbol{\omega}$ é dado pela Eq. (22).

$$\boldsymbol{\omega} = \underset{\boldsymbol{\omega}}{\operatorname{argmin}} \left\{ \frac{1}{m} \sum_{j=1}^m \sum_{t=1}^n \left(Y_{t,j} - \hat{f}_j^L(\boldsymbol{\omega}, \mathbf{x}_t) \right)^2 \right\} \quad (22)$$

Em que $\hat{f}^L(\boldsymbol{\omega}, \mathbf{x}_t) = \left\{ \hat{f}_j^L(\boldsymbol{\omega}, \mathbf{x}_t) \right\}_{j=1}^m$ são mapeamentos não-lineares de $\mathbf{x}_t \rightarrow \mathbf{Y}_t$ resultantes na camada L , chamada camada de saída da ANN. No presente estudo $L = 3$ e o número de neurônios da camada de saída é igual ao número de variáveis endógenas (m) do modelo.

Para otimização da função, ou aprendizagem dos parâmetros, o algoritmo BFGS foi utilizado. Este é um algoritmo *quasi-newton* de aprendizagem por lote que para problemas de menor dimensão (em relação ao número de camadas ocultas e neurônios) possui desempenho superior ao método mais comum de retropropagação de erro (HAYKIN, 2001).

Quando os valores defasados de uma série são utilizados como variáveis de entrada em uma ANN com estrutura de um perceptrom de múltiplas camadas, esta pode ser chamada *time lagged feedforward network* (TLFN). Neste estudo, duas estruturas de ANN foram estimadas. A primeira é um modelo univariado ($m = 1$) tendo como variável de saída o consumo de combustíveis do ciclo Otto e p termos autoregressivos como variáveis de entrada. A segunda é um modelo multivariado ($m = 3$) que projeta conjuntamente o consumo de ciclo Otto, o preço médio dos combustíveis e o PIB *per capita* por meio de p termos autoregressivos de cada uma dessas variáveis como vetor de entrada. Assim como nos vetores autoregressivos tradicionais, o número de defasagens é igual para cada equação das variáveis endógenas.

Os modelos ANN tem como vantagem a possibilidade de mapeamento não-linear entre os vetores de entrada e saída, contudo, um número de interações excessivas pode causar super-encaixe do modelo. Buscando evitar esse problema, além da própria validação cruzada para determinação de hiperparâmetros, um procedimento de parada antecipada foi aplicado, conforme proposto por (HAYKIN, 2001).

3.3.8. Máquinas de Vetores de Suporte (SVM)

Máquina de Vetor de Suporte (SVM) é um modelo não paramétrico capaz de estimar relações não lineares de um vetor de entrada para uma variável de saída, utilizando o chamado truque de kernel (HASTIE *et al.*, 2009).

Este consiste em aplicar nas variáveis de entrada $\left\{ \left\{ \mathbf{x}_{i,t} \right\}_{i=1}^{m_0} \right\}_{t=1}^n$ uma transformação não-linear $\left\{ \left\{ \varphi_j(\mathbf{x}_t) \right\}_{j=1}^{m_1} \right\}_{t=1}^n$ de modo com que a dimensionalidade aumente de m_0 para m_1 . Após isso, o espaço de entrada passa a ser chamado de espaço de características. O objetivo do método é transformar uma relação não linear de $\mathbf{x}_t \rightarrow Y_t$ em uma relação linear de $\boldsymbol{\varphi}(\mathbf{x}_t) \rightarrow Y_t$.

É necessário estimar o vetor de pesos $\boldsymbol{\omega}$ que permita a construção de um hiperplano $L(Y_t, \hat{f}(\boldsymbol{\omega}, \mathbf{x}_t)) = 0$, tal que $\hat{f}(\boldsymbol{\omega}, \mathbf{x}_t) = \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_t) = \sum_{j=0}^{m_1} w_j \varphi_j(\mathbf{x}_t)$, no espaço m_1 dimensional que atenda a condição $|L(Y_t, \hat{f}(\boldsymbol{\omega}, \mathbf{x}_t))| \leq \epsilon$. Em que $L(Y_t, \hat{f}(\boldsymbol{\omega}, \mathbf{x}_t)) = |\hat{f}(\boldsymbol{\omega}, \mathbf{x}_t) - Y_t|$ e ϵ é o limite de tolerância para o erro de previsão realizado pelo mapeamento.

A estimação dos parâmetros ocorre pela resolução do modelo de otimização quadrática cuja função objetivo é dada pela Eq. (23) (HAYKIN, 2001).

$$\begin{aligned}
J(\boldsymbol{\omega}, \boldsymbol{\xi}, \boldsymbol{\xi}', \boldsymbol{\alpha}, \boldsymbol{\alpha}', \boldsymbol{\gamma}, \boldsymbol{\gamma}') &= C \sum_{t=1}^n (\xi_t + \xi'_t) + \frac{1}{2} \boldsymbol{\omega}^T \boldsymbol{\omega} \\
&- \sum_{t=1}^n \alpha_t (\boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_t) - Y_t + \epsilon + \xi_t) - \sum_{t=1}^n \alpha'_t (Y_t - \boldsymbol{\omega}^T \boldsymbol{\varphi}(\mathbf{x}_t) + \epsilon + \xi'_t) \\
&- \sum_{t=1}^n (\gamma \xi_t + \gamma' \xi'_t)
\end{aligned} \quad (23)$$

A Eq. (23) é a função primal do problema de otimização quadrático cujo objetivo é minimizar $J(\boldsymbol{\omega}, \boldsymbol{\xi}, \boldsymbol{\xi}', \boldsymbol{\alpha}, \boldsymbol{\alpha}', \boldsymbol{\gamma}, \boldsymbol{\gamma}')$ em relação aos vetores $\boldsymbol{\omega}, \boldsymbol{\xi}, \boldsymbol{\xi}', \boldsymbol{\alpha}, \boldsymbol{\alpha}', \boldsymbol{\gamma}, \boldsymbol{\gamma}'$. Em que $\boldsymbol{\alpha}, \boldsymbol{\alpha}', \boldsymbol{\gamma}, \boldsymbol{\gamma}'$ são os multiplicadores de Lagrange. A constante C é determinada *a priori*, assim como ϵ , e representa o custo de obter menores erros de treinamento frente ao aumento da complexidade do modelo. O segundo termo é uma penalização pelo aumento da dimensionalidade do modelo que pela teoria do aprendizado estatístico (VAPNIK, 1998) afeta o erro de generalização. No entanto, tomando as condições de primeira ordem da Eq. (23) é possível obter a função dual do problema apresentada na Eq. (24).

$$\begin{aligned}
\max_{\boldsymbol{\alpha}, \boldsymbol{\alpha}'} Q(\boldsymbol{\alpha}, \boldsymbol{\alpha}') &= \sum_{t=1}^n Y_t (\alpha_t - \alpha'_t) - \epsilon \sum_{t=1}^n (\alpha_t - \alpha'_t) \\
&- \frac{1}{2} \sum_{t=1}^n \sum_{j=1}^n (\alpha_t - \alpha'_t) (\alpha_j - \alpha'_j) K(\mathbf{x}_t, \mathbf{x}_j)
\end{aligned} \quad (24)$$

$$\begin{aligned}
s. a \\
\sum_{t=1}^n (\alpha_t - \alpha'_t) &= 0 \\
0 \leq \alpha_t \leq C, i &= 1, 2, \dots, n \\
0 \leq \alpha'_t \leq C, i &= 1, 2, \dots, n
\end{aligned}$$

Na Eq. (24) $K(\mathbf{x}_t, \mathbf{x}_j) = \sum_{j=0}^{m_1} \varphi_j(\mathbf{x}_t) \varphi_j(\mathbf{x}_j) = \boldsymbol{\varphi}^T(\mathbf{x}_t) \boldsymbol{\varphi}(\mathbf{x}_j)$ é chamado função kernel. Na prática, para estimar um SVM não é necessário conhecer a função $\boldsymbol{\varphi}(\mathbf{x})$, apenas a função kernel e que esta atenda ao teorema de Mercer (HAYKIN, 2001). Todos os vetores de entrada \mathbf{x}_t cujo $(\alpha_t, \alpha'_t) \neq 0$ são chamados de vetores de suporte. Na realidade, são essas observações que definem o hiperplano estimado uma vez que o vetor de pesos ótimo será dado por $\boldsymbol{\omega} = \sum_{t=1}^n (\alpha_t - \alpha'_t) \boldsymbol{\varphi}(\mathbf{x}_t)$ e o valor previsto para uma entrada \mathbf{x}_h será $Y_h = \sum_{t=1}^n (\alpha_t - \alpha'_t) K(\mathbf{x}_h, \mathbf{x}_t)$.

O SVM possui boa capacidade de generalização (evita super-encaixe), possibilita o mapeamento não linear dos vetores de entrada e saída, e faz uso de programação quadrática

para estimação dos parâmetros (esta é mais veloz em relação aos métodos iterativos para problemas não lineares). No entanto, a determinação dos hiperparâmetros e do Kernel utilizado podem exigir um alto número de simulações e grande capacidade computacional.

3.3.9. Sistema Neuro-Fuzzy Híbrido (HyFIS)

A teoria *fuzzy* se iniciou com o trabalho de Zadeh (1965), que visava introduzir um aspecto de incerteza em variáveis linguísticas. A lógica *fuzzy*, ao contrário da *booleana*, assume que um conjunto A do universo de discurso Ω é definido por uma função de pertinência $\mu_A: \Omega \rightarrow [0,1]$. A função $\mu_A(x)$ indica o grau de compatibilidade entre x e o conceito expresso por A . Assim, um elemento x pode ser completamente ou parcialmente compatível/incompatível com um conjunto. É possível ainda realizar operações de intersecção e união de conjuntos nebulosos por meio dos operadores t-norma e t-conorma, respectivamente. Para mais detalhes acerca da teoria de lógica *fuzzy* ver Ross (2010).

Os controles nebulosos são formas de estabelecer relações entre variáveis linguísticas a partir da modelagem de regras ligando uma condição (Se) a uma consequência (Então). Os sistemas que misturam os paradigmas dos sistemas nebulosos e de redes neurais podem ser chamados “neuro-*fuzzy*” (BERGMEIR; BEN, 2015; JANG, J.-S. R.; SUN; MIZUTANI, 1997; JANG, J. R., 1993; KIM; KASABOV, 1999).

No presente estudo foi implementado o método Sistema de Inferência Neuro-Fuzzy Híbrido (*Hybrid Neural Fuzzy Inference System* – HyFIS) (KIM; KASABOV, 1999). Neste caso o sistema de controle *fuzzy* é estruturado como uma perceptron de múltiplas camadas e o método de inferência é o de Mamdani (1974). O treinamento divide-se em 2 etapas: aprendizagem das regras, que objetiva identificar, a partir dos dados, a base de regras do sistema *fuzzy*; e, aprendizagem de parâmetros, que busca identificar os parâmetros ótimos. Considerando $y_k^{(l)}$ a saída do neurônio k da camada l , o perceptron é estruturado da seguinte forma:

- **Camada 1:** Camada cujos neurônios (k) representam as entradas. O número de neurônios da camada é igual ao número de variáveis de entrada do modelo: $y_k^{(1)} = x_i, i = 1, \dots, p$;
- **Camada 2:** Camada cujos neurônios (k) transformam, ou “fuzzyficam”, os valores da primeira camada aplicando-os a uma função de pertinência, que no caso do HyFis, utiliza-se a função gaussiana (Eq. 25). A saída dessa camada é a pertinência dos valores de entrada em relação a um valor linguístico específico. O número de neurônios da

camada é igual a cardinalidade do espaço de discurso (L) de cada variável de entrada:

$$y_k^{(2)} = \mu_A(x_i);$$

$$\mu_A(x) = \exp\left(-\frac{(x - c_A)^2}{\sigma_A^2}\right) \quad (25)$$

- **Camada 3:** Camada cujos neurônios (k) aplica uma t-norma de mínimo sobre o valor das funções de pertinência calculadas na camada anterior que impactam uma regra específica (calculando o “poder de fogo” da regra). O número de neurônios da camada é igual ao número de regras: $y_k^{(3)} = \min_{i \in I_j} [y_i^{(2)}]$, I_j =conjunto de neurônios da camada 2 conectado com neurônio k da camada 3;
- **Camada 4:** Camada cujos neurônios (k) aplica uma t-conorma de máximo sobre o resultado numérico da camada anterior. O número de neurônios da camada é igual a cardinalidade do espaço de discurso de cada variável de saída: $y_k^{(4)} = \max_{i \in I_j} [y_i^{(3)}]$, I_j =conjunto de neurônios da camada 3 conectado com neurônio k da camada 4;
- **Camada 5:** Camada cujos neurônios fazem a transformação inversa, ou “defuzzyficam”, os valores linguísticos e computam a saída final da rede por meio do método do centro de gravidade, dado pela Eq. (26).

$$y_l^{(5)} = \frac{\sum_{k \in I_l} y_k^{(4)} \sigma_{lk} c_{lk}}{\sum_{k \in I_l} y_k^{(4)} \sigma_{lk}} \quad (26)$$

Em que $y_l^{(5)}$ é a saída l (assumindo múltiplas saídas) da camada 5; I_l representa o conjunto de neurônios k da camada 4 conectados ao neurônio l da camada 5; σ_{lk} e c_{lk} é o desvio padrão e a média da função de pertinência cuja variável de saída $y_k^{(4)}$ refere-se.

A etapa de aprendizagem de regras é realizada utilizando o procedimento proposto por Wang e Mendel (1992). Para a etapa de aprendizagem de parâmetros minimiza-se Eq. (22) por meio do algoritmo de retropropagação de erro, sendo nesse caso $\hat{f}_j(\omega, \mathbf{x}_t) = y_l^{(5)}$ e $\omega = \{\sigma_{lk}, c_{lk}\}$.

Nas vantagens do algoritmo está a possibilidade de mapeamento não linear dos vetores de entrada e saída e a simplicidade de interpretação das regras. No entanto, é exigido uma grande capacidade computacional para execução das etapas de aprendizado e para determinação dos hiperparâmetros.

3.3.10. Random Forest

O modelo de *Random Forest* pode ser entendido como um método de aprendizagem conjunta, os quais utilizam árvores de decisão para realização das previsões de y_t em função de um vetor de entrada \mathbf{x}_t . Neste caso, diversas árvores de regressão são estimadas e a previsão final do algoritmo é dada pela média das previsões das árvores (BREIMAN, 2001; HASTIE *et al.*, 2009).

Supondo que um conjunto $\{T_b\}_{b=1}^B$ de árvores de regressão serão estimadas a fim de mapear a relação $\mathbf{x} \rightarrow Y$, então as seguintes etapas são realizadas pelo algoritmo:

1. Obter randomicamente uma subamostra de tamanho n_b da amostra de treinamento.
2. Gerar uma árvore de regressão T_b com a amostra simulada realizando recursivamente os seguintes passos até que para cada nó terminal o tamanho mínimo n_{min}^b seja atingido, ou $\max_s \Delta \xi_L(s)$, definido pela Eq. (29), seja inferior a um limite de tolerância:
 - i. Selecionar aleatoriamente m variáveis do vetor p -variado \mathbf{x} ;
 - ii. Tomar, dentre as m variáveis, aquela cuja divisão dentro do nó é ótima;
 - iii. Gerar dois subnós pela divisão da variável escolhida.
3. As observações restantes nos nós terminais são utilizadas para a previsão de uma árvore individualmente dada por $T(\mathbf{x}, \Theta_b)$. Em que Θ_b representa as variáveis selecionadas, os pontos de divisão ótimo e as observações em cada nó terminal.
4. O valor da previsão para um vetor de entrada \mathbf{x} é dado por $\hat{f} = \frac{1}{B} \sum_{b=1}^B T(\mathbf{x}, \Theta_b)$.

Sabendo que existe um conjunto de S divisões possíveis para os nós de uma árvore T_b , a escolha do ponto ótimo de quebra dos nós é realizado conforme o algoritmo CART para árvores de decisão (BREIMAN *et al.*, 1984). Neste caso, inicia-se com um único nó com todas as observações e, progressivamente, faz-se divisões dos nós que irão surgindo. Tomando um nó l pertencente a uma árvore T_B a previsão dentro do nó é dada pela Eq. (27).

$$\hat{f}_l = \frac{\sum_{\mathbf{x}_t \in l} Y_t}{n_l} \quad (27)$$

Em que n_l é o número de observações pertencentes ao nó l . Definindo a soma quadrados dentro do nó e a soma de quadrados da árvore conforme as equações 28 e 29, a divisão ótima $s^* \in S$ em um nó l é aquela que maximiza a redução em ξ_L dada por $\Delta \xi_L$, conforme a Eq. (30).

$$\xi_l = \sum_{\mathbf{x}_i \in l} (Y_i - \hat{f}_l)^2 \quad (28)$$

$$\xi_L = \sum_{l \in T_B} \xi_l \quad (29)$$

$$s^* = \underset{s}{\operatorname{argmax}} \Delta \xi_L(s) \quad (30)$$

Os modelos *Random Forest* possuem uma fácil interpretação e a procura por hiperparâmetros ótimos não requer tanta atividade computacional quanto outros algoritmos. Por ser uma espécie de modelo de aprendizagem conjunta costuma gerar previsões com variância relativamente menor.

3.3.11. Grey Models

O modelo Grey, proposto por Julong (1989), é uma metodologia não paramétrica cuja principal vantagem é a possibilidade de modelar sistemas mesmo com poucos dados disponíveis. O objetivo da técnica é inferir sobre o comportamento da geração da série ao invés dos dados brutos. No presente estudo foi implementado um modelo de primeira ordem e univariado GM (1,1).

As duas operações básicas da Grey prediction são: operação de geração acumulada (*accumulated generating operation* – AGO) e operação de geração acumulada inversa (*inverse accumulated generating operation* – IAGO). Os passos para estimação do modelo são:

1. Tomando a série a ser prevista $\mathbf{y}^0 = \{y_t\}_{t=1}^n$ em que $n \geq 4$ e y_t é não negativo para todo $t = 1, \dots, n$.
2. Aplicando o operador AGO em \mathbf{y}^0 podemos obter a série $\mathbf{y}^1 = \{y_k^1\}_{k=1}^n$ que é monotonicamente crescente, dada pela Eq. (31).

$$y_k^1 = \sum_{t=1}^k y_t^0 \quad (31)$$

3. Tomando uma equação diferencial de primeira ordem, conforme a Eq. (32), como forma para o GM.

$$y_t^0 + aZ_t^1 = b, t = 1, \dots, T \quad (32)$$

Em que

$$Z_t^1 = \theta y_t^1 + (1 - \theta)y_{t-1}^1 \quad (33)$$

Os parâmetros a e b são estimados utilizando mínimos quadrados ordinários considerando y_t^0 como variável dependente. O valor de $\theta \in [0,1]$ foi determinado utilizando o procedimento de validação cruzada descrito na seção 3.3.14 da metodologia.

4. A partir dos parâmetros estimados e resolvendo a equação diferencial (Eq. 32) obtemos a Eq. (34) utilizada para predição de \hat{y}_{t+1}^1 .

$$\hat{y}_{t+1}^1 = \left[y_1^0 - \frac{b}{a} \right] e^{at} + \frac{b}{a} \quad (34)$$

Finalmente, aplicando o operador IAGO podemos obter a equação de previsão para a série original, dada pela Eq. (35).

$$\hat{y}_{t+1}^0 = \hat{y}_{t+1}^1 - \hat{y}_t^1 = (1 - e^a) \left[y_1^0 - \frac{b}{a} \right] e^{-at} \quad (35)$$

É comum utilizar apenas as n observações mais recentes para estimação do modelo visando elevar a acurácia das previsões (AKAY; ATAK, 2007). O valor de n para se estimar os parâmetros foi determinado, assim como o valor de θ , por meio do processo de validação cruzada. O processo de estimação e previsão h passos-à-frente é realizado dinamicamente atualizando o subconjunto dos dados utilizados. Quando a escolha de θ e n é feita de forma experimental, neste caso com o procedimento de validação cruzada, o GM passa a ser chamado OGM (*Optimized Grey Model*) (HAMZACEBI; ES, 2014).

3.3.12. Modelos Híbridos

Modelos híbridos são aqueles que combinam paradigmas de diferentes algoritmos de previsão para formulação de um modelo único. Neste caso, o processo de estimação dos parâmetros (aprendizagem) ocorre de forma conjunta. Comumente uma série pode apresentar atributos lineares e não-lineares simultaneamente, o uso de modelos híbridos permite capturar diferentes padrões dentro de uma mesma série (ZHANG, 2003).

Uma aplicação muito comum de modelos híbridos para previsão de uma série Y_t consiste na divisão da série em dois componentes, um linear (L_t) e outro não-linear (N_t). O procedimento consiste na aplicação de um algoritmo para modelagem da componente linear, comumente utiliza-se um modelo Arima, e outro para a não-linear (BARAK; SADEGH, 2016; MAIA; DE CARVALHO; LUDERMIR, 2008; ZHANG, 2003).

No presente estudo, a separação das componentes foi realizada baseado em Babu e Reddy (2014) com algumas adaptações. Neste último, uma decomposição com médias móveis é utilizada para separar a série em um componente de tendência (assumido como linear) e outro composto pela sazonalidade e resíduos (assumidos como não-lineares). Considera-se que cada componente segue um processo autoregressivo separável.

Assim, o procedimento proposto neste trabalho segue os seguintes passos:

1. Utilizando uma decomposição STL a série é separada em um componente de tendência, assumido como linear, e outro contendo o resíduo e sazonalidade da série assumidos como não-lineares.
2. O componente linear é modelado por um modelo Arima selecionado a partir dos procedimentos discutidos na seção 3.3.3.

3. O componente não-linear é modelado por uma Máquina de Vetor de Suporte (SVM) em que os hiperparâmetros são determinados por procedimentos de validação cruzada discutidos na sessão 3.3.14.
4. A previsão final é obtida pela soma das duas componentes estimadas nos passos 2 e 3.

Outras estruturas foram testadas alterando o algoritmo de aprendizagem da componente não-linear para os modelos ANN e *Random Forest*. No entanto apenas o de melhor desempenho será apresentado nos resultados.

Para outras aplicações de modelos híbridos na previsão de consumo de energia que não necessariamente sigam a este paradigma de decomposição de séries temporais ver Deb *et al.*, (2017) e Debnath e Mourshed (2018).

3.3.13. Modelos de aprendizagem conjunta (*Ensemble Learning*)

Os modelos de aprendizagem conjunta têm por objetivo combinar os resultados de diferentes algoritmos para reduzir a variância do erro das previsões e aumentar sua acurácia. A forma mais usual baseia-se na combinação linear das predições conforme as equações 36 e 37.

$$\hat{\mathbf{y}} = \hat{\mathbf{Y}}\mathbf{W} \quad (36)$$

$$\sum_j^J w_j = 1 \quad (37)$$

Em que $\hat{\mathbf{y}}$ é um vetor de previsão combinada com dimensão $T \times 1$, $\hat{\mathbf{Y}}$ é uma matriz $T \times J$ contendo as previsões dos J diferentes algoritmos para os T períodos previstos e \mathbf{W} é o vetor de dimensão $J \times 1$ que contém os pesos w_j para combinação linear das previsões.

A partir da Eq. (37) é possível obter a esperança e a matriz de covariância do vetor de erros do modelo combinado \mathbf{e}_c conforme as Eq. (38) e (39).

$$E(\mathbf{e}_c) = E(\mathbf{y} - \hat{\mathbf{y}}) = E(\mathbf{e})\mathbf{W} \quad (38)$$

$$VAR(\mathbf{e}_c) = \mathbf{Q} = \mathbf{W}^T\mathbf{V}\mathbf{W} \quad (39)$$

Em que \mathbf{e} é uma matriz $T \times J$ contendo os erros dos J diferentes algoritmos para os T períodos previstos e \mathbf{V} é a matriz de covariância dos erros em que na diagonal principal encontram-se $VAR(e_j) j = 1, \dots, J$.

Assumindo que as previsões individualmente são não-viesadas, então a previsão combinada também não será. A variância do modelo combinado dependerá de \mathbf{W} , de modo com que é possível reduzi-la com a escolha adequada dos pesos.

Os resultados de estudos que propõe a combinação de previsões têm sido unânime em favor da melhoria da acurácia de previsão (HYNDMAN; ATHANASOPOULOS, 2018). No

entanto, quando o vetor de peso \mathbf{W} tem de ser estimado, surgem complicações nos resultados das equações 38 e 39 e, por isso, muitas vezes a utilização de pesos fixos baseado na média simples das previsões apresentam resultados superiores a metodologias complexas de estimação de pesos.

Esse aspecto tem sido chamado de “quebra cabeça da combinação de previsões” (*forecast combination puzzle*) e estimulado o desenvolvimento de diversos estudos cujo objetivo é explorar os fundamentos e propor formas de determinar os pesos ideais (BLANC; SETZER, 2016; CHAN; PAUWELS, 2018; CLAESKENS *et al.*, 2013; CLEMEN, R., 1989; HSIAO; WAN, 2014).

Neste estudo, 4 formas de combinação de previsões foram avaliadas do ponto de vista empírico. O primeiro estima os pesos por meio de mínimos quadrados restritos (MQO) impondo que a soma dos pesos seja igual a um (BATES; GRANGER, 1969; ELLIOTT, 2011; GRANGER; RAMANATHAN, 1984).

O segundo utiliza da Análise de Componentes Principais (PC) para estimativa dos pesos. Esse método é comumente utilizado para problemas de redução de dimensionalidade em algoritmos de aprendizagem de máquina. Seu objetivo é sumarizar um vetor de p variáveis em m índices, tal que $m \leq p$, que capturem o máximo da variação dessas por meio da decomposição da matriz de correlação (ou covariância) das variáveis (JOHNSON; WICHERN, 2007). Para a previsão combinada, as componentes principais são construídas a partir de uma combinação linear das J previsões, e os pesos dessa combinação é igual ao autovetor correspondente ao maior autovalor da matriz de correlação entre elas. O valor de cada peso é normalizado (dividindo pela soma dos pesos) para que seja igual a um.

O terceiro utiliza Análise Fatorial (FA) para estimativa dos pesos. Semelhante ao anterior, o objetivo dessa técnica consiste na criação de m fatores através da combinação linear de um vetor de p variáveis, tal que $m \leq p$, capazes de sumarizar a variação destas. O procedimento, para tanto, pode se distinguir muito da PC. Sumariamente o método consiste em decompor a matriz de correlação das previsões em uma componente explicada pelos m fatores e outra aleatória de modo com que essa última seja a menor possível. Para isso utilizou-se a estimação por máxima verossimilhança das matrizes. Em seguida os pesos podem ser calculados conforme Johnson e Wichern (2007, p. 514) e então normalizados para que sua soma seja igual a um.

As três metodologias anteriores utilizam as previsões dentro da amostra de treinamento para estimativa dos pesos. Por fim, uma média simples (MED) das previsões completa os

métodos combinados de previsão. Para mais aplicações de modelos combinados para previsão de consumo de diversas fontes energéticas ver Wang e Srinivasan (2017).

3.3.14. Métricas de avaliação e testes estatísticos para comparação de algoritmos

Para avaliação dos diferentes métodos de previsão, um processo iterativo foi conduzido a fim de testar estatisticamente a diferença de acurácia dos modelos. As seguintes etapas foram executadas:

1. Um corte inicial é feito na série de consumo de ciclo Otto deixando apenas os dados de janeiro de 2002 a dezembro de 2011.
2. Essa subsérie é utilizada para estimativa dos modelos e realização da previsão h passos-à-frente. O RMSE é calculado, conforme a Eq. (42), e armazenado como medida de acurácia no período. Neste caso, cada período de corte possui um valor de RMSE para a previsão h passos-à-frente.
3. Uma nova observação é adicionada a base de treino e o passo 3 é repetido.

Os passos 3 e 4 são repetidos até que a previsão h passos-à-frente tenha como último período previsto a última observação conhecida dos dados. Assim obtém-se uma série com o RMSE para cada ponto no tempo e para cada modelo.

As performances são ranqueadas para cada período e o teste de Friedman é realizado para verificar se existe diferença entre o ranking médio de um algoritmo i , dado por \bar{r}_i , e o desempenho médio de todos os modelos \bar{r} . Em seguida, o teste de Nemenyi é realizado para comparação entre pares de métodos. Este teste também é baseado no ranqueamento dos modelos, segundo uma métrica de erro, para cada período analisado.

O método cujo ranking médio for o menor será apontado como o de melhor performance. Para mais informações sobre os testes no contexto de comparação de métodos de previsão ver Demsar (2006) e Shingala (2016).

As equações 40 e 41 apresentam as hipóteses nulas e alternativas de cada teste.

Friedman	H0: $\bar{r}_i = \bar{r}$, não há diferença entre o ranking dos métodos no geral.	(40)
	HA: $\bar{r}_i \neq \bar{r}$, há diferença entre o ranking dos métodos no geral.	

Nemenyi	H0: $\bar{r}_i = \bar{r}_j \forall i \neq j$, não há diferença entre o ranking dos métodos i e j .	(41)
	HA: $\bar{r}_i \neq \bar{r}_j \forall i \neq j$, há diferença entre o ranking dos métodos i e j .	

Uma metodologia ingênua de previsão é proposta como comparativo com o intuito de verificar a superioridade dos métodos em relação a um modelo com baixo custo de implementação. Neste caso, os meses do último ano serão utilizados como previsão para um ano subsequente. Esse método é recomendado para dados com sazonalidade.

O RMSE foi utilizado como critério de seleção dos modelos no procedimento de validação cruzada uma vez que quase todos os métodos utilizam uma função de erro quadrático médio para estimativa do vetor de parâmetros. No entanto, será apresentado o Erro Absoluto Percentual Médio (*Mean Absolute Square Error* – MAPE) para cada ponto no tempo (isto é, para a previsão h passos à frente a partir daquela data), calculado conforme a Eq. (43), com o objetivo de facilitar a interpretação dos resultados pela exclusão da questão dimensional nos erros. Adicionalmente, o valor máximo e mínimo do Erro Percentual (EP) considerando o horizonte de previsão h passos à frente também é apresentado. A seguir estão as fórmulas que foram utilizadas no cálculo desses indicadores.

$$RMSE_t = \sqrt{\frac{1}{h} \sum_{j=1}^h (Y_j - \hat{Y}_j)^2} \quad (42)$$

$$MAPE_t = \frac{100\%}{h} \sum_{j=1}^h \frac{|Y_j - \hat{Y}_j|}{Y_j} \quad (43)$$

$$\max EP_t = \max \left\{ \frac{|Y_j - \hat{Y}_j|}{Y_j} \right\}_{j=1}^h \quad (44)$$

$$\min EP_t = \min \left\{ \frac{|Y_j - \hat{Y}_j|}{Y_j} \right\}_{j=1}^h \quad (45)$$

3.4. RESULTADOS E DISCUSSÃO

3.4.1. Resultados da validação cruzada

A Tabela 9 apresenta os resultados da escolha dos hiperparâmetros baseado no procedimento de validação cruzada ou nos critérios de informação. Os modelos cujos parâmetros são escolhidos em função do horizonte de previsão apresentam uma quebra para 3, 6 e 12 meses.

Tabela 9: Hiperparâmetros selecionados a partir dos procedimentos de validação cruzada e critérios de informação.

Modelo	Tratamento da Sazonalidade	Pré-processamento dos Dados	Hiperparâmetros Ótimos		
Sarima	Termo autoregressivo sazonal	Logaritmo	$p = 2, d = 1, q = 3$ $P = 1, D = 0, Q = 1$		
Arima ^{c/} Binárias	Variáveis binárias	Logaritmo	$p = 5, d = 1, q = 5$		
VEC	Variáveis binárias	Logaritmo	$p = 5, r = 2$		
Modelo Estrutural	Variáveis binárias	Logaritmo	3 meses	$\delta = 0,81$	
			6 meses	$\delta = 0,82$	
			12 meses	$\delta = 0,83$	
STL	Separação pelo próprio STL	Logaritmo	$n_{(p)} = 12, n_{(i)} = 1, n_{(o)} = 15, n_{(l)} =$ $n_{(s)} = 13, n_{(r)} = 21,$ $d_l = d_r = 1, d_s = 0$		
ANN	Filtro de Médias Móveis	Padronização pela média e desvio-padrão	3 meses	$p = 3, k_1 = 1, k_2 = 2$	
			6 meses	$p = 5, k_1 = 1, k_2 = 5$	
			12 meses	$p = 4, k_1 = 1, k_2 = 2$	
Multi ANN	3 meses	Filtro de Médias Móveis	Padronização pela média e desvio-padrão	3 meses	$p = 4, k_1 = 10, k_2 = 10$
	6 meses	Filtro de Médias Móveis		6 meses	$p = 3, k_1 = 4, k_2 = 0$
	12 meses	Variáveis binárias		12 meses	$p = 3, k_1 = 10, k_2 = 9$
SVM	Filtro de Médias Móveis	Padronização pela média e desvio-padrão	3 meses	$p = 3, \epsilon = 0,1, C = 6,$ kernel=gaussiano	
			6 meses	$p = 3, \epsilon = 0,1, C = 10,$ kernel=gaussiano	
			12 meses	$p = 3, \epsilon = 0,1, C = 10,$ kernel=gaussiano	
Hyfis	Filtro de Médias Móveis	Padronização pela média e desvio-padrão	3 meses	$p = 3, L = 22$	
			6 meses	$p = 3, L = 22$	
			12 meses	$p = 3, L = 16$	
Random Forest	Filtro de Médias Móveis	Sem transformação	3 meses	$p = 6, B = 100, m = 5,$ $n_{min}^B = 6$	
			6 meses	$p = 6, B = 100, m = 4,$ $n_{min}^B = 3$	
			12 meses	$p = 6, B = 100, m = 5,$ $n_{min}^B = 5$	
Grey Model	Filtro de Médias Móveis	Sem transformação	3 meses	$n = 19, \theta = 0,9$	
			6 meses	$n = 18, \theta = 0,9$	
			12 meses	$n = 18, \theta = 0,9$	

Modelos Híbridos	Separação pelo STL e termo autoregressivo sazonal	Logaritmo	3 meses	$p_L = 3, d = 1, q = 0$ $p_{NL} = 2, \epsilon = 0,1, C = 1,$ kernel=gaussiano
			6 meses	$p_L = 3, d = 1, q = 0$ $p_{NL} = 1, \epsilon = 0,9, C = 1,$ kernel=gaussiano
			12 meses	$p_L = 3, d = 1, q = 0$ $p_{NL} = 1, \epsilon = 0,1, C = 10,$ kernel=gaussiano

Esse procedimento diminui a possibilidade de super-encaixe do modelo estimado e permite a comparação e seleção dos hiperparâmetros que geram o menor erro de previsão fora da amostra de treinamento.

3.4.2. Resultados dos erros de previsão e comparação dos modelos

Buscando comparar as performances de previsão dos diferentes métodos, foram realizados os testes de ranking de Friedman e Nemenyi. Primeiramente foi desconsiderada a comparação com os modelos combinados, visando eleger os algoritmos com desempenhos individuais superiores.

A Tabela 10 apresenta os rankings médios de cada método e, concomitantemente, o resultado do teste de Friedman. Nesse teste, a hipótese nula é dada pela homogeneidade do desempenho dos modelos, avaliando se os rankings individuais são estatisticamente iguais ao ranking médio. Foram avaliados 12 métodos e do método ingênuo. Essa avaliação envolve 69 pontos no tempo para o cenário de 12 meses, 75 pontos no caso de 6 meses e 78 pontos na projeção de 3 meses.

Tabela 10: Ranks médios dos modelos e resultado do teste de Friedman.

Modelo	Rank Médio (12 meses)	Rank Médio (6 meses)	Rank Médio (3 meses)
SVM	4,71	5,29	5,83
SAR.Bin	4,80	5,37	5,35
VECM	5,96	5,63	5,35
RF	6,07	6,33	7,18
ANN	6,23	5,64	5,58
HYFIS	6,30	6,87	6,86
SAR	6,58	6,49	6,21
GM	7,03	6,79	6,99
STL	7,26	7,08	6,97
HM	7,78	8,67	8,49
DLM	8,20	8,67	8,40
Seas.Naive	9,96	10,76	10,55
MANN	10,12	7,41	7,26
Média Geral	7,00	7,00	7,00
p-valor Teste Friedman (Ha: Desempenhos diferentes)	0,00	0,00	0,00

O teste de Nemenyi permite comparar os modelos entre si e o resultado é apresentado nas Figuras 17 a 19. O melhor algoritmo identificado por este procedimento foi o SVM, seguido do SAR.Bin e do VECM para a previsão de 12 e 6 meses. Apenas no caso do horizonte de 3 meses esses modelos ultrapassaram a performance do SVM.

No entanto, considerando um intervalo de confiança de 95%, não é possível afirmar que os primeiros 7 modelos mais bem ranqueados possuem performance estatisticamente inferiores ao SVM na previsão de 12 meses. O mesmo é válido para a previsão 6 e 3 meses à frente. O intervalo de confiança é representado nas Figuras 17 a 19 pela área cinza.




Figura 17: Resultado e intervalo de confiança do teste de Nemenyi para previsão 12 meses à frente.




Figura 18: Resultado e intervalo de confiança do teste de Nemenyi para previsão 6 meses à frente.




Figura 19: Resultado e intervalo de confiança do teste de Nemenyi para previsão 3 meses à frente.

As performances dos métodos mais bem ranqueados foram estatisticamente superiores ao modelo ingênuo. Esse fato sugere maior robustez desses procedimentos, contrapondo o maior custo computacional necessário para implementação dos mesmos.

Para comparar mais facilmente a performance dos modelos em termos de erro de previsão, as Tabelas 11 a 12 apresentam a média e desvio-padrão do MAPE da previsão, a média do MAPE da amostra de treinamento⁷, o valor máximo e mínimo do MAPE e o máximo erro percentual de cada modelo considerando todos os períodos utilizados na validação.

No Apêndice 3 é apresentada a série completa com a evolução do MAPE, do erro percentual mínimo e máximo dos modelos em cada período do tempo. Isto é, em um mês qualquer, qual seria o valor dessas métricas considerando a previsão dos próximos 3, 6 ou 12 meses.

Tabela 11: Resumo da performance dos métodos para previsão de 12 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
SVM	2,78%	2,12%	1,11%	5,67%	1,47%	11,61%
SAR.Bin	2,89%	1,92%	1,44%	8,40%	1,22%	16,21%
VECM	2,91%	1,99%	1,21%	7,31%	1,34%	16,78%

⁷ O GM não possui MAPE de treinamento uma vez que apenas parte a amostra de treino é utilizada para estimação do modelo. Logo, o número de períodos utilizados para o cálculo é incompatível com o dos outros métodos.

RF	3,05%	2,66%	1,33%	6,43%	1,71%	12,03%
GM	3,20%	-	1,39%	8,60%	1,74%	16,14%
ANN	3,25%	2,21%	1,48%	7,24%	1,52%	13,24%
HYFIS	3,26%	2,98%	1,50%	7,14%	1,21%	12,81%
SAR	3,32%	2,15%	1,67%	8,58%	1,25%	19,71%
DLM	3,39%	3,35%	1,47%	8,55%	1,85%	20,70%
STL	3,41%	2,42%	1,53%	8,93%	1,31%	16,36%
HM	3,74%	1,76%	2,42%	16,80%	1,89%	34,34%
Seas Naive	4,62%	-	1,71%	7,37%	1,98%	13,23%
MANN	4,71%	2,31%	1,87%	9,34%	1,35%	21,58%

Tabela 12: Resumo da performance dos métodos para previsão de 6 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
SAR.Bin	2,45%	1,92%	0,99%	6,07%	0,97%	11,43%
SVM	2,47%	2,12%	0,81%	4,48%	1,11%	8,94%
VECM	2,53%	1,99%	1,01%	5,17%	0,79%	10,10%
ANN	2,54%	2,20%	0,93%	5,85%	0,69%	9,45%
RF	2,66%	2,64%	0,96%	5,34%	1,20%	9,73%
SAR	2,68%	2,15%	1,20%	6,29%	1,06%	13,81%
GM	2,74%	-	0,93%	6,18%	1,24%	10,67%
HYFIS	2,74%	2,67%	1,02%	5,34%	0,90%	10,22%
STL	2,84%	2,42%	1,04%	6,68%	1,17%	9,95%
DLM	3,14%	3,35%	1,34%	7,67%	0,96%	16,72%
MANN	3,33%	3,25%	1,99%	12,56%	2,00 %	18,42%
HM	3,54%	2,39%	1,73%	11,00%	1,23%	17,75%
Seas Naive	4,65%	-	1,94%	8,64%	1,24%	13,23%

Tabela 13: Resumo da performance dos métodos para previsão de 3 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
SAR.Bin	2,28%	1,92%	1,17%	6,06%	0,49%	11,79%
VECM	2,28%	1,99%	1,23%	5,63%	0,64%	9,19%
SVM	2,35%	2,12%	1,03%	5,54%	0,68%	7,97%
ANN	2,40%	2,20%	1,09%	5,11%	0,51%	8,05%
SAR	2,42%	2,15%	1,29%	7,31%	0,67%	13,20%
HYFIS	2,56%	2,66%	1,18%	5,45%	0,70%	9,46%
GM	2,58%	-	1,09%	5,78%	0,33%	9,05%
RF	2,58%	2,65%	1,17%	5,68%	0,54%	9,44%
STL	2,65%	2,42%	1,10%	6,72%	0,66%	9,16%
MANN	2,77%	3,26%	1,29%	6,88%	0,79%	10,93%
DLM	3,06%	3,35%	1,57%	7,67%	0,43%	13,76%
HM	3,24%	2,23%	1,82%	9,52%	0,73%	12,87%
Seas Naive	4,72%	-	2,26%	9,54%	0,95%	13,23%

As Tabelas 11 a 13 acabam por refletir os resultados obtidos no teste de Nemenyi. O SVM, SAR.Bin e VECM lideram com as melhores acurácias de previsão. Importante destacar que os modelos com menor MAPE médio não necessariamente serão aqueles indicados como superiores pelo teste de Nemenyi, pois este é realizado a partir do ranqueamento dos métodos nos períodos avaliados.

Com exceção do HM e do MANN para 12 meses, aparentemente nenhum método possui problema de super-encaixe, uma vez que os erros de treinamento e validação não destoam de forma considerável. Esse fato é importante para garantir a eficiência do processo de escolha dos modelos e garantia da generalização fora da amostra de treino.

O aumento do horizonte de previsão implica em um aumento do MAPE Médio dos modelos que possuem maior acurácia na previsão de 3 meses, seguido da previsão de 6 e então 12 meses. Conseqüentemente, o MAPE e erros percentuais máximos se reduzem gradativamente conforme o horizonte de previsão também é reduzido. Nota-se, ainda, que o aumento do número de períodos previstos acarreta maior heterogeneidade dos *rankings*, visto que há um aumento considerável do ranking médio do primeiro para o quarto colocado para previsão de 12 meses. O SVM distancia-se dos outros métodos conforme o horizonte de previsão aumenta.

Apesar dos testes de verificação do modelo SAR terem sido superiores ao SAR.Bin, a acurácia das previsões deste segundo o colocam como um modelo mais adequado. Este resultado indica a importância da etapa de validação fora da amostra de treinamento e a limitação dos testes tradicionais na escolha de modelos cujo objetivo é a previsão de dados.

As previsões realizadas para períodos contemplando os meses de fevereiro de 2014 a agosto de 2016 e abril de 2017 até agosto de 2018 evidenciam um aumento generalizado do erro de previsão de todos os métodos (ver apêndice 3). O primeiro período citado inclui choques ocasionados pela crise econômica no Brasil e pelo impeachment da presidente Dilma Rousseff. No segundo período, por sua vez, ocorreu a paralização da categoria dos caminhoneiros.

Buscando avaliar a estabilidade do erro de previsão, pode-se analisar o desvio padrão do MAPE e o máximo erro percentual dentro de um ponto no tempo. O SVM, cujo ranking de performance foi o melhor dentre todos os métodos na previsão de 12 e 6 meses, também obteve o menor desvio padrão do MAPE considerando todos os horizontes. Considerando o maior horizonte de previsão, o erro percentual máximo desse modelo foi de 11,6% e o MAPE máximo de 5,7%. Por outro lado, o modelo SAR.Bin, cujo ranking foi o segundo melhor, possui o quinto maior desvio padrão, erro percentual máximo de 16,2% e MAPE máximo de 8,4%.

Vale destacar que o aumento do horizonte de previsão, em linhas gerais, não promoveu aumento do desvio-padrão do MAPE. Isto é, os modelos não passaram a ter performance mais instável em relação a sua média apenas pela quantidade de períodos previstos. Um modelo com instabilidade de performance ou com previsões que diferem substancialmente do valor real da série em alguns momentos pode vir a ser descartado mesmo quando seu MAPE médio é inferior a outros métodos. A decisão quanto a tolerância máxima deve ser baseada no custo esperado da decisão utilizando uma previsão incorreta.

Após essa análise inicial, os modelos de aprendizagem conjunta foram implementados considerando as previsões dos 3 melhores métodos para cada horizonte de previsão, sendo estes SVM, SAR.Bin e VECM.


3.4.3. Resultados dos Modelos de Aprendizagem Conjunta

A partir dos valores previstos dentro da amostra de treinamento os pesos dos modelos de aprendizagem conjunta, ou modelos combinados, foram calculados. Esse processo é realizado de forma dinâmica, com um novo vetor de pesos sendo gerado para cada ponto no tempo da validação cruzada.

Os testes de Friedman e Nemenyi são reavaliados incluindo os métodos combinados. A Tabela 14 apresenta o ranking médio dos modelos e as Figuras 20 a 22 o resultado do teste de Nemenyi.

Tabela 14: Ranks médios dos modelos individuais e combinados e resultado do teste de Friedman.

Modelo	Rank Médio (12 meses)	Rank Médio (6 meses)	Rank Médio (3 meses)
MQO	6,45	6,69	6,92
MED	6,52	6,72	6,79
PC	6,63	6,70	6,76
FA	6,63	6,70	6,76
SVM	6,96	7,57	8,12
SAR.Bin	7,00	7,65	7,59
RF	8,33	8,75	9,88
VECM	8,41	8,11	7,77
HYFIS	8,68	9,52	9,68
ANN	9,04	8,21	7,79
SAR	9,46	8,99	8,33
GM	9,65	9,60	9,78
STL	10,26	9,92	9,73
HM	10,88	11,69	11,55
DLM	11,20	11,65	11,29
MANN	13,51	10,20	10,12
Seas Naive	13,38	14,32	14,13
Média Geral	9,00	9,00	9,00
p-valor Teste Friedman	0,00 (Ha: Desempenhos diferentes)	0,00 (Ha: Desempenhos diferentes)	0,00 (Ha: Desempenhos diferentes)

**Figura 20:** Resultado e intervalo de confiança do teste de Nemenyi para previsão 12 meses à frente.




Figura 21: Resultado e intervalo de confiança do teste de Nemenyi para previsão 6 meses à frente.




Figura 22: Resultado e intervalo de confiança do teste de Nemenyi para previsão 3 meses à frente.

As Tabelas 15 a 17 expõem o resultado da média e desvio padrão do MAPE, assim como os erros percentuais dos modelos combinados.

Tabela 15: Resumo da performance dos métodos combinados para previsão de 12 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
MQO	2,68%	1,88%	1,21%	7,89%	1,15%	15,33%
MED	2,65%	1,90%	0,95%	6,75%	1,23%	14,01%
PC	2,65%	1,90%	0,95%	6,75%	1,23%	14,01%
FA	2,65%	1,90%	0,95%	6,75%	1,23%	14,01%

Tabela 16: Resumo da performance dos métodos combinados para previsão de 6 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
MQO	2,34%	1,88%	0,91%	5,68%	0,85%	10,23%
MED	2,33%	1,90%	0,82%	4,98%	0,88%	9,85%
PC	2,33%	1,90%	0,82%	4,98%	0,88%	9,85%
FA	2,33%	1,90%	0,82%	4,98%	0,88%	9,85%

Tabela 17: Resumo da performance dos métodos combinados para previsão de 3 meses à frente.

Modelo	MAPE Médio	MAPE Médio (Treinamento)	Desvio Padrão MAPE	Max MAPE	Min MAPE	Max EP
MQO	2,15%	1,88%	1,14%	5,54%	0,54%	9,05%
MED	2,18%	1,90%	1,08%	5,54%	0,54%	8,83%
PC	2,18%	1,90%	1,08%	5,54%	0,54%	8,83%
FA	2,18%	1,90%	1,08%	5,54%	0,54%	8,83%

Embora os modelos combinados tenham menores erros de previsão, os testes performados não rejeitam a hipótese nula de que sua acurácia é tão boa quanto aquela gerada pelos métodos individuais.

Do ponto de vista de desvio padrão do MAPE e, conseqüentemente, estabilidade da acurácia de previsão, percebe-se uma superioridade marginal dos modelos combinados em relação ao SAR.Bin e VECM. Porém, o SVM permanece com o menor desvio padrão para a previsão de 3 e 6 meses. O mesmo é válido para o MAPE e erro percentual máximo. Apenas em relação ao SAR.Bin e VECM os modelos combinados são superiores.

O método de combinação MQO, embora não possua o menor MAPE médio no horizonte de previsão de 6 e 12 meses, é apontado como melhor modelo pelo teste. Como já destacado, isso ocorre, pois, esse procedimento está baseado no ranqueamento dos modelos em cada período de tempo. Assim, o melhor método é aquele que consegue performar de forma superior aos outros no maior número de períodos.

A evolução dos coeficientes ao longo do tempo para cada metodologia de combinação e horizonte de previsão é apresentada nas Figuras 23 a 25.

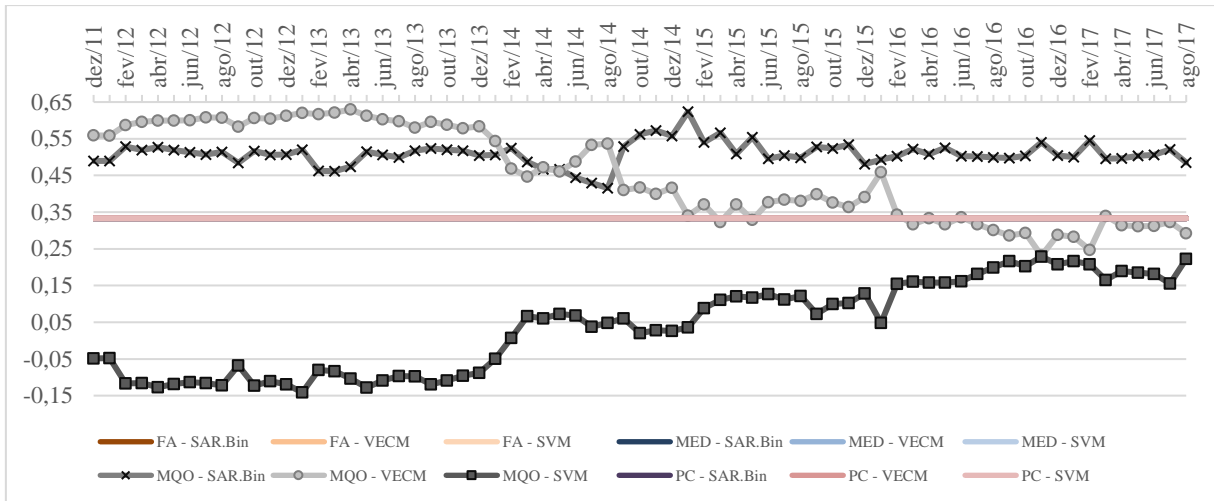


Figura 23: Pesos estimados para os modelos de aprendizagem conjunta para o horizonte de previsão de 12 meses.




Figura 24: Pesos estimados para os modelos de aprendizagem conjunta para o horizonte de previsão de 6 meses.

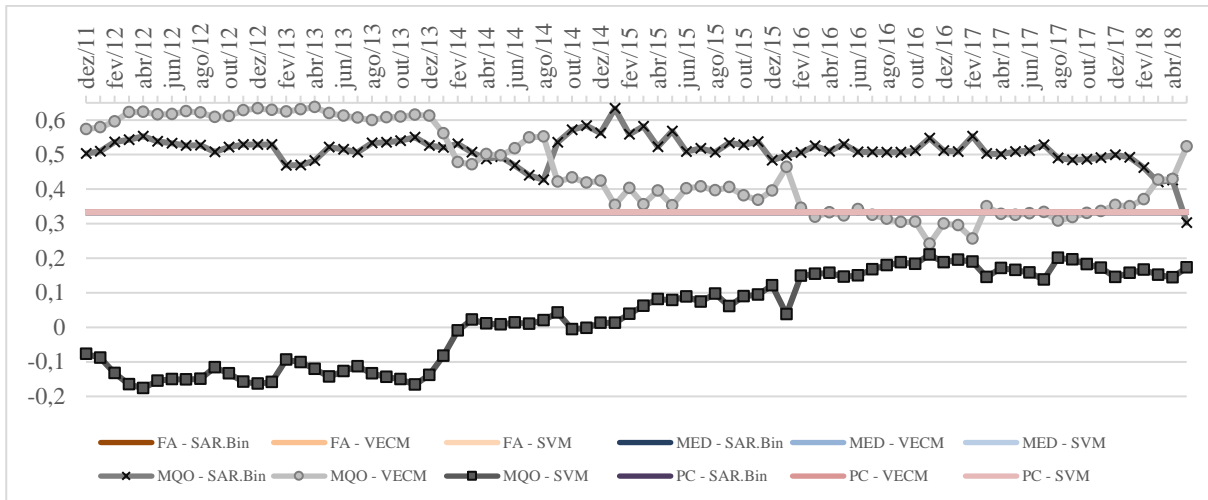


Figura 25: Pesos estimados para os modelos de aprendizagem conjunta para o horizonte de previsão de 3 meses.

Os pesos calculados para a análise de componentes principais e análise fatorial são muito próximos a uma ponderação pela média aritmética das previsões. Isso se deve ao fato de que as previsões individuais possuem uma correlação muito elevada e contribuem igualmente para a decomposição da matriz de covariância entre elas. Logo, os métodos atribuem pesos idênticos para cada uma das variáveis.

Como resultado, a performance das combinações por meio da média ou utilizando as duas técnicas são quase equivalentes. Nota-se que o peso estimado por MQO restrito para o SVM é negativo no início da série e aumenta gradativamente com o passar do tempo. Isso é decorrencia do maior erro de treinamento nos meses iniciais (ver Apêndice 4). Nos períodos seguintes, sua importância dentro do modelo de aprendizagem conjunta se eleva conforme o erro de treinamento diminui.

3.5. CONCLUSÕES

O presente estudo comparou diferentes métodos para a previsão do consumo de combustíveis de ciclo Otto no Brasil. O procedimento de validação cruzada permitiu estimar o erro de generalização dos modelos e o MAPE médio obtido foi inferior a 3% em todos os horizontes de previsão. Adicionalmente, os métodos com melhor desempenho se mostraram significativamente superiores ao modelo ingênuo de previsão.

Mesmo em períodos de grande incerteza, o desempenho dos modelos se mostrou estável, com opções de modelos cujo erro máximo mensal se manteve em 11,61% para a previsão de 12 meses e foi inferior a 10% para os períodos de 6 e 3 meses.

Em síntese, é possível concluir que, a despeito das mudanças tecnológicas, de mercado e institucionais observadas no setor brasileiro de combustíveis leves nos últimos 10 anos, os modelos de previsão avaliados indicam que é possível realizar projeções para o consumo de combustíveis leves com bom nível de acurácia.

Os resultados indicam que esse tipo de abordagem é relevante para o planejamento dos agentes privados. Isso porque, é comum haver cláusula contratual enunciando multas quando existem alterações no volume de combustível comprado ou vendido em relação aquele estabelecido inicialmente em contrato, seja nas operações domésticas ou na importação desses produtos.

A projeção do consumo total de combustíveis leves também se mostra útil para esses agentes na definição de ações operacionais e de investimento relacionadas à produção, à distribuição, ao transporte e à revenda de combustíveis no País.

No caso do setor público, os modelos implementados podem ser utilizados no dimensionamento dos recursos para ajuste na capacidade de produção doméstica, bem como de infraestrutura logística necessária para o suprimento da demanda por transporte. Além disso, no caso brasileiro, a projeção do consumo é fundamental na definição das metas decenais da Política Nacional de Biocombustível, visto que essa é uma das variáveis de entrada do modelo econômico utilizado para fundamentação técnica do programa (CRBIO, 2020).

A boa acurácia dos modelos também indica que os mesmos podem ser adotados na definição e operacionalização de regras e normas de comercialização definidas para o mercado nacional. Entre elas, é possível mencionar os contratos de compra e venda de etanol anidro induzidos pela Resolução ANP N° 67/2011 (ANP, 2020). Atualmente a referida resolução exige que a contratação prévia do biocombustível para o ano seguinte seja baseada no volume comercializado de gasolina no ano corrente e na mistura obrigatória vigente.

Por fim, a análise aqui conduzida não esgota a necessidade de novos estudos relacionados ao tema. Modelos para a realização de projeções regionais e para prever a demanda individual de cada combustível são importantes para um entendimento mais profundo do tema. Além disso, sob o ponto de vista metodológico, abordagens alternativas para a combinação de modelos que não dependam das previsões dentro da amostra de treinamento para cálculo dos pesos devem ser avaliadas. Finalmente, estudos para avaliar o impacto estrutural da recente pandemia de COVID-19 sobre o consumo de combustíveis no futuro são fundamentais para uma análise completa sobre o tema.

REFERÊNCIAS

- AHMAD, A. S. *et al.* A review on applications of ANN e SVM for building electrical energy consumption forecasting. *Renewable e Sustainable Energy Reviews*, v. 33, p. 102–109, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.rser.2014.01.069>>.
- AKAY, D.; ATAK, M. Grey prediction with rolling mechanism for electricity demand forecasting of Turkey. *Energy*, v. 32, p. 1670–1675, 2007.
- AL-GHANDOOR, A. *et al.* Residential past e future energy consumption: Potential savings e environmental impact. *Renewable e Sustainable Energy Reviews*, v. 13, n. 6–7, p. 1262–1274, 2009.
- ANP – AGÊNCIA NACIONAL DE PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS. Dados Estatísticos. 2018. Disponível em: < <http://www.anp.gov.br/dados-estatisticos> > . Acesso em: 19 set. 2018.
- ANP – AGÊNCIA NACIONAL DE PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS. Resolução ANP nº 67, de 9.12.2011. 2020. Disponível em: < <http://legislacao.anp.gov.br/?path=legislacao-anp/resol-anp/2011/dezembro&item=ranp-67-2011> > . Acesso em: 31 out. 2020.
- BACEN – BANCO CENTRAL DO BRASIL. Séries Temporais. 2018. Disponível em: < <http://www4.bcb.gov.br/pec/series/port/aviso.asp> > . Acesso em: 19 set. 2018.
- BABU, C. N.; REDDY, B. E. A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. *Applied Soft Computing Journal*, v. 23, p. 27–38, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.asoc.2014.05.028>>.
- BARAK, S.; SADEGH, S. S. Forecasting energy consumption using ensemble ARIMA–ANFIS hybrid algorithm. *Electrical Power e Energy Systems*, v. 82, p. 92–104, 2016. Disponível em: <<http://dx.doi.org/10.1016/j.ijepes.2016.03.012>>.
- BATES, J. M.; GRANGER, C. W. J. The Combination of Forecasts. *Operational Research Quarterly*, v. 20, n. 4, p. 451–468, 1969.
- BERGMEIR, C.; BEN, M. frbs : Fuzzy Rule-Based Systems for Classification. *Journal of Statistical Software*, v. 65, n. 6, p. 1–30, 2015.
- BERGMEIR, C.; HYNDMAN, R. J.; KOO, B. A note on the validity of cross-validation for evaluating autoregressive time series prediction. *Computational Statistics e Data Analysis*, v. 120, p. 70–83, 2018. Disponível em: <<https://doi.org/10.1016/j.csda.2017.11.003>>.
- BLANC, S. M.; SETZER, T. When to choose the simple average in forecast combination. *Journal of Business Research*, v. 69, n. 10, p. 3951–3962, 2016.
- BOX, G. E. P.; JENKINS, G. M.; REINSEL, G. C. *Time Series Analysis: Forecasting e Control*. 4ed. ed. New Jersey: John Wiley & Sons, 2008. v. 20. Disponível em: <<https://press.princeton.edu/titles/5386.html>>.
- BREIMAN, L. *et al.* *Classification e Regression Trees*. New York: CRC Press, 1984.
- BREIMAN, L. Random Forests. *Machine Learning*, v. 45, p. 5–32, 2001.
- BUENO, R. DE L. DA S. *Econometria de Séries Temporais*. 2ª ed. São Paulo: Cengage Learning, 2018.
- BURNQUIST, H. L.; BACCHI, M. R. P. A demanda por gasolina no Brasil: uma análise utilizando técnicas de co-integração. 2000. p. 1–13.

CASTRO, G. R. DE. *Modelo de Previsão de Demanda por Combustíveis Automotivos no Brasil*. 2012. 71 f. Universidade Federal do Rio de Janeiro, 2012.

CHAN, F.; PAUWELS, L. L. Some theoretical results on forecast combinations. *International Journal of Forecasting*, v. 34, n. 1, p. 64–74, 2018. Disponível em: <<http://dx.doi.org/10.1016/j.ijforecast.2017.08.005>>.

CHANG, P. C.; FAN, C. Y.; LIN, J. J. Monthly electricity demand forecasting based on a weighted evolving fuzzy neural network approach. *International Journal of Electrical Power e Energy Systems*, v. 33, n. 1, p. 17–27, 2011.

CHE, J.; WANG, J. Short-term load forecasting using a kernel-based support vector regression combination model. *Applied Energy*, v. 132, p. 602–609, 2014. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0306261914007478>>.

CHEN, Y. *et al.* Short-term electrical load forecasting using the Support Vector Regression (SVR) model to calculate the demand response baseline for office buildings. *Applied Energy*, v. 195, p. 659–670, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.apenergy.2017.03.034>>.

CLAESKENS, G. *et al.* A Simple Theoretical Explanation of the Forecast Combination Puzzle. *International Journal of Forecasting*, v. 32, p. 754–762, 2013.

CLEMEN, R. Combining forecasts: A review e annotated bibliography. *International Journal of Forecasting*, v. 5, n. 4, p. 559–583, 1989. Disponível em: <<http://www.sciencedirect.com/science/article/pii/0169207089900125>>.

CLEVELAND, R. B. *et al.* STL: A seasonal-trend decomposition procedure based on loess. *Journal of Official Statistics*, v. 6, n. 1, p. 3–73, 1990.

CNPE – Conselho Nacional de Política Energética (2020). “Resolução No 8, de 18 de agosto de 2020”. <http://www.mme.gov.br/documents> (Acesso em 19 de Agosto de 2020).

COIN, D. Testing normality in the presence of outliers. *Statistical Methods e Applications*, v. 17, n. 1, p. 3–12, 2008.

CRBIO – Comitê RenovaBio (2020). “Consulta Pública No 94 de 5 de junho de 2020”. <http://www.mme.gov.br/web/guest/conselhos-e-comites/crbio> (Acesso em 19 de Agosto de 2020).

DE FREITAS, L. C.; KANEKO, S. Ethanol demand under the flex-fuel technology regime in Brazil. *Energy Economics*, v. 33, n. 6, p. 1146–1154, nov. 2011. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S014098831100079X>>. Acesso em: 16 mar. 2019.

DEB, C. *et al.* A review on time series forecasting techniques for building energy consumption. *Renewable e Sustainable Energy Reviews*, v. 74, n. March, p. 902–924, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.rser.2017.02.085>>.

DEBNATH, K. B.; MOURSHED, M. Forecasting methods in energy planning models. *Renewable e Sustainable Energy Reviews*, v. 88, n. August 2016, p. 297–325, 2018. Disponível em: <<https://doi.org/10.1016/j.rser.2018.02.002>>.

DEMSAR, J. Statistical Comparisons of Classifiers over Multiple Data Sets. *Journal of Machine Learning Research*, v. 7, p. 1–30, 2006.

DICKEY, D. A.; PANTULA, S. G. Determining the Order of Differencing in Autoregressive Processes. *Journal of Business & Economic Statistics*, v. 5, n. 4, p. 455–461, 1987.

- DUDEK, G. Short-Term Load Forecasting using Random Forests. In: D FILEV *et al.* (Org.). *Intelligent Systems '2014. Advances in Intelligent Systems e Computing*. Cham: Springer, 2015. v. 323. p. 821–828. Disponível em: <https://doi.org/10.1007/978-3-319-11310-4_71>.
- EBRAHIMPOUR, R. *et al.* Mixture of mlp-experts for trend forecasting of time series: A case study of the tehran stock exchange. *International Journal of Forecasting*, v. 27, n. 3, p. 804–816, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.ijforecast.2010.02.015>>.
- EDGERTON, D.; SHUKUR, G. Testing autocorrelation in a system perspective testing autocorrelation. *Econometric Reviews*, v. 18, n. 4, p. 343–386, 1999.
- EDIGER, V. Ş.; AKAR, S. ARIMA forecasting of primary energy demand by fuel in Turkey. *Energy Policy*, v. 35, n. 3, p. 1701–1708, 2007. Disponível em: <<http://linkinghub.elsevier.com/retrieve/pii/S0301421506002291>>.
- EDIGER, V. Ş.; AKAR, S.; UĞURLU, B. Forecasting production of fossil fuel sources in Turkey using a comparative regression e ARIMA model. *Energy Policy*, v. 34, n. 18, p. 3836–3846, 2006.
- ELLIOTT, G. *Averaging e the Optimal Combination of Forecasts*. 2011. Disponível em: <<http://citeseerx.ist.psu.edu/viewdoc/summary?doi=10.1.1.700.8168>>.
- ELLIOTT, G.; ROTHENBERG, T. J.; STOCK, J. H. Efficient Tests for an Autoregressive Unit Root. *Econometrica*, v. 64, n. 4, p. 813–836, 1996. Disponível em: <<http://www.jstor.org/stable/2171846?origin=crossref>>.
- ENGLE, R. F. Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation. *Econometrica*, v. 50, n. 4, p. 987–1007, 1982.
- FAN, S.; CHEN, L.; LEE, W. J. Machine learning based switching model for electricity load forecasting. *Energy Conversion e Management*, v. 49, n. 6, p. 1331–1344, 2008.
- FIGUEIRA, S. R.; BURNQUIST, H. L. Programas para álcool combustível nos Estados Unidos e possibilidades de exportação do Brasil. *Agricultura em São Paulo*, v. 53, n. C, p. 5–18, 2006.
- GARCÍA NIETO, P. J. *et al.* PM10 concentration forecasting in the metropolitan area of Oviedo (Northern Spain) using models based on SVM, MLP, VARMA e ARIMA: A case study. *Science of the Total Environment*, v. 621, p. 753–761, 2018. Disponível em: <<https://doi.org/10.1016/j.scitotenv.2017.11.291>>.
- GRANGER, C. W. J.; RAMANATHAN, R. Improved Methods of Combining Forecasts. *Journal of Forecasting*, v. 3, n. July 1982, p. 197–204, 1984.
- HAMZACEBI, C.; ES, H. A. Forecasting the annual electricity consumption of Turkey using an optimized grey model. *Energy*, v. 70, p. 165–171, 2014. Disponível em: <<http://dx.doi.org/10.1016/j.energy.2014.03.105>>.
- HARVEY, A. C.; PETERS, S. Estimation procedures for structural time series models. *Journal of Forecasting*, v. 9, n. 2, p. 89–108, 1990.
- HARVEY, ANDREW C. *Forecasting, Structural Time Series Models e the Kalman Filter*. Cambridge: Cambridge University Press, 1990. v. 58.
- HARVEY, ANDREW C.; SHEPHARD, N. Structural time series models. In: MADDALA, G. S.; RAO, C. R.; VINOD, H. D. (Org.). *Handbook of Statistics*. Elsevier Science Publishers, 1993. v. 11. p. 261–302.
- HASTIE, T. *et al.* *The Elements of Statistical Learning*. Nova York: 2nd ed. Springer, 2009.

- HONG, W. Electric load forecasting by support vector model. *Applied Mathematical Modelling*, v. 33, n. 5, p. 2444–2454, 2009. Disponível em: <<http://dx.doi.org/10.1016/j.apm.2008.07.010>>.
- HSIAO, C.; WAN, S. K. Is there an optimal forecast combination? *Journal of Econometrics*, v. 178, p. 294–309, 2014.
- HYNDMAN, R. J. *et al. Forecasting with Exponential Smoothing*. Berlin: Springer, 2008.
- HYNDMAN, R. J.; ATHANASOPOULOS, G. *Forecasting: Principles e Practice*. 2nd ed. Melbourne: Otexts, 2018.
- IBARRA-BERASTEGI, G. *et al.* Short-term forecasting of the wave energy flux: Analogues, random forests, e physics-based models. *Ocean Engineering*, v. 104, p. 530–539, 2015.
- IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. População. 2019. Disponível em: <<https://www.ibge.gov.br/estatisticas/sociais/populacao>>. Acesso em: 19 mar. 2019.
- ISLAS, J.; MANZINI, F.; MASERA, O. A prospective study of bioenergy use in Mexico. *Energy*, v. 32, n. 12, p. 2306–2320, 2006.
- JANG, J.-S. R.; SUN, C.-R.; MIZUTANI, E. *Neuro-Fuzzy e Soft Computing: A computational Approach to Learning e Machine Intelligence*. New Jersey: Prentice Hall, 1997.
- JANG, J. R. ANFIS: Adaptive-Network-Based Fuzzy Inference System. *IEEE TRANSACTIONS ON SYSTEMS, MAN, E CYBERNETICS*, v. 23, n. 3, p. 665–685, 1993.
- JOHANSEN, S. Estimation e Hypothesis Testing of Cointegration Vectors in Gaussian Vector. *Econometrica*, v. 59, n. 6, p. 1551–1580, 1991.
- JOHANSEN, S. Statistical analysis of cointegration vectors. *Journal of Economic Dynamics e Control*, v. 12, n. 2–3, p. 231–254, 1988.
- JOHANSSON, O.; SCHIPPER, L. Measuring the Long-Run Fuel Demand of Cars: Separate Estimations of Vehicle Stock, Mean Fuel Intensity, e Mean Annual Driving Distance. *Journal of Transport Economics e Policy*, v. 31, n. 3, p. 277–292, 1997.
- JOHNSON, R. A.; WICHERN, D. W. *Applied Multivariate Statistical Analysis*. 6th. ed. New Jersey: Pearson Education, 2007.
- JULONG, D. Introduction to Grey Systems Theory. *The Journal of Grey System*, v. 1, p. 1–24, 1989.
- KADIR KAVAKLIOGLU, HALIM CEYLAN , HARUN KEMAL OZTURK, O. E. C. Modeling e prediction of Turkey’s electricity consumption using Artificial Neural Networks. *Energy Conversion e Management*, v. 50, n. 11, p. 2719–2727, 2009. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2009.06.016>>.
- KANDANANOND, K. Forecasting electricity demand in Thailand with an artificial neural network approach. *Energies*, v. 4, n. 8, p. 1246–1257, 2011.
- KHASHEI, M.; BIJARI, M. An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with Applications*, v. 37, n. 1, p. 479–489, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.eswa.2009.05.044>>.
- KIM, J.; KASABOV, N. HyFIS : adaptive neuro-fuzzy inference systems e their application to nonlinear dynamical systems. *Neural Networks*, v. 12, p. 1301–1319, 1999.

KUCUKALI, S.; BARIS, K. Turkey's short-term gross annual electricity demand forecast by fuzzy logic approach. *Energy Policy*, v. 38, n. 5, p. 2438–2445, 2010.

KUHN, M.; JOHNSON, K. *Applied Predictive Modeling*. New York: Springer, 2013. Disponível em: <http://www.amazon.com/Applied-Predictive-Modeling-Max-Kuhn/dp/1461468485/ref=pd_bxgy_b_img_z>.

KWIATKOWSKI, D. *et al.* Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root? *Journal of Econometrics*, v. 54, p. 159–178, 1992. Disponível em: <<http://files.eric.ed.gov/fulltext/ED523995.pdf%5Cnhttp://eric.ed.gov/?id=ED523995>>.

LAHOUAR, A.; BEN HADJ SLAMA, J. Day-ahead load forecast using random forest e expert input selection. *Energy Conversion e Management*, v. 103, p. 1040–1051, 2015. Disponível em: <<http://dx.doi.org/10.1016/j.enconman.2015.07.041>>.

LÜTKEPOHL, H. *New Introduction to Multiple Time Series Analysis*. 2. ed. Berlin: Springer, 2005.

M.J., K. *et al.* Comparison of ARIMA e Random Forest time series models for prediction of avian influenza H5N1 outbreaks. *BMC bioinformatics*, v. 15, p. 276, 2014. Disponível em: <<http://www.embase.com/search/results?subaction=viewrecord&from=export&id=L373985864%0Ahttp://dx.doi.org/10.1186/1471-2105-15-276>>.

MAIA, A. L. S.; DE CARVALHO, F. D. A. T.; LUDERMIR, T. B. Forecasting models for interval-valued time series. *Neurocomputing*, v. 71, n. 16–18, p. 3344–3352, 2008.

MAMDANI, E. H. Application of fuzzy algorithms for control of simple dynamic plant. *Proceedings of the Institution of Electrical Engineers*, v. 121, n. 12, p. 1585–1588, 1974.

MELIKOGLU, M. Demand forecast for road transportation fuels including gasoline, diesel, LPG, bioethanol and biodiesel for Turkey between 2013 and 2023. *Renewable Energy*, v. 64, p. 164-171, 2014.

MOREIRA, A. R. B. *Modelos para a Projeção do Consumo Nacional e Regional de Óleo Diesel*. Rio de Janeiro, 1996. Disponível em: <http://www.ipea.gov.br/portal/index.php?option=com_content&view=article&id=3635&Itemid=1>.

MU, H. *et al.* Grey relative analysis e future prediction on rural household biofuels consumption in China. *Fuel Processing Technology*, v. 85, n. 8–10, p. 1231–1248, 2004.

NASR, G. .; BADR, E. .; JOUN, C. Backpropagation neural networks for modeling gasoline consumption. *Energy Conversion e Management*, v. 44, n. 6, p. 893–905, 2003. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0196890402000870>>.

NELSON, M. *et al.* Time series forecasting using neural networks: Should the data be deseasonalized first? *Journal of Forecasting*, v. 18, n. 5, p. 359–367, 1999.

NENGLING, T.; STENZEL, J.; HONGXIAO, W. Techniques of applying wavelet transform into combined model for short-term load forecasting. *Electric Power Systems Research*, v. 76, n. 6–7, p. 525–533, 2006.

NIE, H. *et al.* Hybrid of ARIMA e SVMs for short-term load forecasting. *Energy Procedia*, v. 16, n. PART C, p. 1455–1460, 2011. Disponível em: <<http://dx.doi.org/10.1016/j.egypro.2012.01.229>>.

OSBOM, D. R. *et al.* Seasonality e the Order of Integration for Consumption. *Oxford Bulletin of Economics e Statistics*, v. 50, n. 4, p. 361–377, 1988.

- PADMAKUMARI, K.; MOHANDAS, K. P.; THIRUVENGADAM, S. Long term distribution demand forecasting using neuro fuzzy computations. *International Journal of Electrical Power e Energy System*, v. 21, n. 5, p. 315–322, 1999.
- PAI, P. F. Hybrid ellipsoidal fuzzy systems in forecasting regional electricity loads. *Energy Conversion e Management*, v. 47, n. 15–16, p. 2283–2289, 2006.
- PAO, H. T.; TSAI, C. M. Modeling e forecasting the CO2 emissions, energy consumption, e economic growth in Brazil. *Energy*, v. 36, n. 5, p. 2450–2458, 2011.
- PETRIS, G.; PETRONE, S. State Space Models in R. *Journal of Statistical Software*, v. 41, n. 4, p. 1–25, 2011.
- RINGWOOD, J. V; BOFELLI, D.; MURRAY, F. T. Forecasting Electricity Demand on Short, Medium e Long Time Scales Using Neural Networks. *Journal of Intelligent e Robotic Systems*, v. 31, n. May, p. 129–147, 2001.
- RODRIGUES, L.; BACCHI, M. R. P. Analyzing light fuel demand elasticities in Brazil using cointegration techniques. *Energy Economics*, v. 63, p. 322–331, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.eneco.2017.02.012>>.
- RODRIGUES, L.; PIEDADE BACCHI, M. R. Light fuel demand and public policies in Brazil, 2003-2013. *Applied Economics*, v. 48, n. 54, p. 5300–5313, 2016. Disponível em: <<http://dx.doi.org/10.1080/00036846.2016.1176115>>.
- RODRIGUES, L.; RODRIGUES, L. Economic-financial performance of the Brazilian sugarcane energy industry: An empirical evaluation using financial ratio, *cluster* e discriminant analysis. *Biomass e Bioenergy*, v. 108, n. October 2017, p. 289–296, 2018. Disponível em: <<https://doi.org/10.1016/j.biombioe.2017.11.013>>.
- ROSS, T. J. *Fuzzy Logic with Engineering Applications*. 3 ed ed. Chichester: John Wiley & Sons, 2010.
- SANTIAGO, F. S.; DE MATTOS, R. S.; PEROBELLI, F. S. Um modelo integrado econométrico+insumo-produto para previsão de longo prazo da demanda de combustíveis no Brasil. *Nova Economia*, v. 21, n. 3, p. 423–455, 2011.
- SHAPIRO, S. S.; WILK, M. B. An Analysis of Variance Test for Normality (Complete Samples). *Biometrika*, v. 52, n. 4, p. 591–611, 1965.
- SHINGALA, M. C. *Comparison of different post HOC tests*. 2016. 188 f. Veer Narmad South Gujarat University, 2016. Disponível em: <<http://hdl.handle.net/10603/171827>>.
- SIMON HAYKIN. *Redes Neurais: Princípios e Prática*. 2 ed ed. Porto Alegre: Bookman, 2001.
- SMITH, C.; HALL, S.; MABEY, N. Econometric modelling of international carbon tax regimes. *Energy Economics*, v. 17, n. 2, p. 133–146, 1995.
- SÖZEN, A.; ARCAKLIOĞLU, E.; ÖZKAYMAK, M. Turkey's net energy consumption. *Applied Energy*, v. 81, n. 2, p. 209–221, 2005.
- SUGANTHI, L.; SAMUEL, A. A. Energy models for demand forecasting — A review. *Renewable e Sustainable Energy Reviews*, v. 16, p. 1223–1240, 2012.
- VAPNIK, V. N. *Statistical Learning Theory*. New York: John Wiley & Sons, 1998.
- WANG, L. X.; MENDEL, J. M. Generating Fuzzy Rules by Learning from Examples. *IEEE Transactions on Systems, Man e Cybernetics*, v. 22, n. 6, p. 1414–1427, 1992.

WANG, Z.; SRINIVASAN, R. S. A review of artificial intelligence based building energy use prediction: Contrasting the capabilities of single e ensemble prediction models. *Renewable e Sustainable Energy Reviews*, v. 75, n. November 2016, p. 796–808, 2017. Disponível em: <<http://dx.doi.org/10.1016/j.rser.2016.10.079>>.

WEI, C. C.; CHEN, T. T.; LEE, S. J. K-NN based neuro-fuzzy system for time series prediction. *14th ACIS International Conference on Software Engineering, Artificial Intelligence, Networking e Parallel/Distributed Computing*, p. 569–574, 2013.

WEST, M.; HARRISON, J. *Bayesian Forecasting e Dynamic Models*. 2nd. ed. New York: Springer, 1997.

XIA, C.; WANG, J.; MCMENEMY, K. Short, medium e long term load forecasting model e virtual load forecaster based on radial basis function neural networks. *International Journal of Electrical Power e Energy Systems*, v. 32, n. 7, p. 743–750, 2010. Disponível em: <<http://dx.doi.org/10.1016/j.ijepes.2010.01.009>>.

ZADEH, L. A. Fuzzy Sets. *Information e Control*, v. 8, n. 3, p. 338–353, 1965.

ZANINI, A.; SOUZA, R. C.; PEDREIRA, C. E. *Um modelo híbrido para previsão de curto prazo da demanda de gasolina automotiva no Brasil*. 2001. 403–407 f. Pontifícia Universidade Católica do Rio de Janeiro - PUC-RIO, 2001.

ZHANG, G. P. Time series forecasting using a hybrid ARIMA e neural network model. *Neurocomputing*, v. 50, n. 0, p. 159–175, 2003. Disponível em: <http://www.sciencedirect.com/science/article/pii/S0925231201007020%5Cnhttp://0-www.sciencedirect.com.innopac.up.ac.za/science/article/pii/S0925231201007020%5Cnhttp://0-www.sciencedirect.com.innopac.up.ac.za/science?_ob=MiamiImageURL&_cid=271597&_user=5938>.

ZHANG, G. P.; QI, M. Neural network forecasting for seasonal e trend time series. *European Journal of Operational Research*, v. 160, n. 2, p. 501–514, 2005.

4. CONCLUSÕES

O mercado brasileiro de combustíveis leves apresenta características que não são observadas em outras nações do globo. Sob o ponto de vista institucional, são evidentes as mudanças na forma de atuação do Estado nesse mercado ao longo de toda a sua história. Sob o ponto de vista tecnológico, trata-se da única economia com presença maciça de veículos e motocicletas *flex-fuel*. Por fim, o país foi pioneiro no uso do etanol combustível, seja na mistura do produto com a gasolina ou no seu uso diretamente nos veículos.

Essa condição estabelece uma dinâmica única para o mercado nacional e fomenta necessidade de estudos para avaliar essa sistemática nas suas diferentes esferas. Trata-se, assim, de uma área importante para pesquisas e análises aplicadas visando fundamentar as ações dos agentes que atuam nesse setor e nos setores correlatos.

Nesse contexto, a presente pesquisa buscou explorar dois elementos importantes desse mercado e ainda pouco avaliados pela literatura especializada.

A começar pela ótica da demanda, foram avaliados diferentes métodos para a previsão do consumo total de combustíveis leves no País, que engloba a gasolina, o etanol e o GNV. A despeito das alterações profundas observadas no período de análise, a sistemática proposta permitiu a obtenção de previsões com bom nível de acurácia. Essa avaliação evidencia que o ferramental analítico empregado pode ser útil para avaliações privadas e públicas acerca da demanda futura por combustíveis no mercado nacional.

No caso da oferta, a pesquisa explorou aspectos associados à situação econômico-financeira do setor sucroenergético, que se consolidou como a principal fonte de energia renovável no País.

Nas últimas duas décadas, essa indústria vivenciou grandes turbulências, com um período de expansão acelerada sucedido por uma das maiores crises da sua história. Como resultado desse movimento, diversas empresas deixaram de operar e a produção se estagnou.

Nesse contexto, o presente trabalho, a partir de um banco de dados inédito e de ferramentas amplamente empregadas em análises empíricas, trouxe indicações relevantes sobre a situação da indústria sucroenergética no País e, mais importante, evidenciou a importância das mudanças nos ambientes institucional e de negócios sobre o desempenho das empresas desse setor.

Os resultados obtidos indicaram que houve deteriorização da condição financeira das usinas e destilarias no País na última década. A condição atual da indústria ainda requer cuidados, apesar da presença de empresas com situação econômica adequada. Essa situação

sugere uma avaliação periódica do tema diante da necessidade de ampliação da oferta de etanol combustível nos próximos anos no mercado nacional.

Os resultados de ambos os artigos possuem um ponto de convergência no que diz respeito a oferecer insumos para o desenho e manutenção da Política Nacional de Biocombustível, o RenovaBio. O programa tem por intuito a redução da emissão de gases de efeito estufa derivados do transporte veicular brasileiro por meio do incentivo ao consumo de biocombustíveis frente aos combustíveis fósseis.

O sucesso do programa enquanto política pública depende, dentre outras questões, da capacidade das unidades produtoras de etanol de atender a oferta de etanol necessária para o cumprimento das metas de descarbonização, que ampliam a participação do biocombustível na matriz energética até 2030.

A produção atual de cerca de 30 bilhões de litros atende apenas 60% da necessidade imposta para 2030. A amostra utilizada como base de dados no primeiro artigo contemplou cerca de 70% da produção nacional de etanol (UNICA, 2020). Desta, 31% da produção do biocombustível encontra-se a cargo de empresas dos clusters 3 e 4, que não devem possuir as condições financeiras para aumento da capacidade produtiva no curto prazo.

Como resultado, as empresas responsáveis pelo 69% restantes (aproximadamente 18 bilhões de litros na safra 2018/2019) devem se responsabilizar pelo aumento da capacidade produtiva nos próximos anos de modo a atender, no curto prazo, as necessidades do mercado nacional.

Por fim, ainda sobre as contribuições desse trabalho, vale citar que todo ano as metas impostas pelo RenovaBio para o ano seguinte são revisitadas com o objetivo de verificar sua adequação às condições técnicas e de mercado. A demanda total por combustíveis leves, variável cujo comportamento foi modelado pelos métodos de previsão do segundo artigo, consiste em um dos parâmetros do modelo matemático utilizado como base para definição das metas de descarbonização.

Desse modo, o artigo indica a possibilidade do uso do ferramental dos métodos de previsão para um melhor gerenciamento no processo de revisão das metas no horizonte de 12 meses. A utilização dos métodos propostos é ainda mais ampla, sendo possível adotá-los na operacionalização das normas de comercialização de combustíveis, no dimensionamento da necessidade de importação e produção de derivados e biocombustíveis para abastecimento da frota doméstica.

REFERÊNCIAS

ANP – AGÊNCIA NACIONAL DE PETRÓLEO, GÁS NATURAL E BIOCMBUSTÍVEIS. Resolução ANP nº 67, de 9.12.2011. 2020. Disponível em: <<http://legislacao.anp.gov.br/?path=legislacao-anp/resol-anp/2011/dezembro&item=ranp-67-2011>> . Acesso em: 31 out. 2020.

FARINA, E.; SOUZA, Z. A biomassa de cana quebra paradigmas. *O Estado de S. Paulo*. (2018)
Fonte: <https://www.novacana.com/n/cogeracao/biomassa-cana-quebra-paradigmas-151018>

UNICA – União da Indústria de Cana-de-Açúcar (2020). “Histórico de Produção e Moagem”. <https://observatoriodacana.com.br/> (acessado em 05 de Janeiro de 2021).

APÊNDICES

APÊNDICE 1: Testes Estatísticos do Modelo Sarima e Arima com variáveis binárias

Tabela 18: Teste de duas raízes unitárias de Dickey-Pantula para série de consumo do ciclo otto.

Conclusão do teste Dickey-Pantula	Tipo de Teste	Valor do Teste	Critical Value (5%)
n° de raízes unitárias < 2	Sem termos deterministas	-3.8142	-3.4333
n° de raízes unitárias < 2	Com constante	-5.2328	-3.4334
n° de raízes unitárias < 2	Com tendência e constante	-5.5911	-3.4335

Tabela 19: Teste de raiz unitária DF-GLS para série de consumo do ciclo otto.

Conclusão do teste DF-GLS	Tipo de Teste	Valor do Teste	Critical Value (5%)
Não estacionário	Com tendência	-0.4756	-2.93
Não estacionário	Com constante	1.2701	-1.94

Tabela 20: Teste de raiz unitária KPSS para série de consumo do ciclo otto.

Conclusão do teste KPSS	Tipo de Teste	Test Value	Critical Value (5%)
Não estacionário	Com constante	1.3934	0.463
Não estacionário	Com tendência e constante	0.2629	0.146

Tabela 21: Teste de raiz unitária sazonal OCSB para série de consumo do ciclo otto.

Conclusão do teste OCSB	Test Value	Critical Value (5%)
Não possui raiz unitária sazonal	-5.3775	-1.803

Tabela 22: Teste de autocorrelação dos resíduos do modelo Sarima para a série de consumo do ciclo otto.

Conclusão do teste Ljung-Box (IC=5%)	p-valor	Número de defasagens para ajuste do teste
Não há autocorrelação.	0,9104	2
Não há autocorrelação.	0,6804	4
Não há autocorrelação.	0,8003	6
Não há autocorrelação.	0,6484	12
Não há autocorrelação.	0,7556	18

Tabela 23: Teste de normalidade dos resíduos do modelo Sarima para a série de consumo do ciclo otto.

Conclusão do teste de normalidade (IC=5%)	Teste	p-valor
Não normalmente distribuídos.	Jarque-Bera	0,001785
Não normalmente distribuídos.	Shapiro-Wilk	0,0121

Tabela 24: Teste de heterocedasticidade condicional dos resíduos do modelo Sarima para a série de consumo do ciclo otto.

Conclusão do teste de heterocedasticidade (IC=5%)	Teste	Número de defasagens para ajuste do teste
São homocedásticos.	LM	4, 8, 12, 16

Tabela 25: Teste de autocorrelação dos resíduos do modelo Arima com variáveis binárias para a série de consumo do ciclo otto.

Conclusão do teste Ljung-Box (IC=5%)	p-valor	Número de defasagens para ajuste do teste
Não há autocorrelação.	0,8326	2
Não há autocorrelação.	0,9756	4
Não há autocorrelação.	0,9874	6
Não há autocorrelação.	0,9896	12
Não há autocorrelação.	0,9971	18

Tabela 26: Teste de normalidade dos resíduos do modelo Arima com variáveis binárias para a série de consumo do ciclo otto.

Conclusão do teste de normalidade (IC=5%)	Teste	p-valor
Não normalmente distribuídos.	Jarque-Bera	$2,2 \times 10^{-16}$
Não normalmente distribuídos.	Shapiro-Wilk	$5,2 \times 10^{-6}$

Tabela 27: Teste de heterocedasticidade condicional dos resíduos do modelo Arima com variáveis binárias para a série de consumo do ciclo otto.

Conclusão do teste de heterocedasticidade (IC=5%)	Teste	Número de defasagens para ajuste do teste
Não são homocedásticos.	LM	4, 8, 12, 16




Figura 26: Comparação da frequência dos resíduos do modelo Sarima de consumo de ciclo otto com uma distribuição normal padrão.




Figura 27: Comparação da frequência dos resíduos do modelo Sarima de consumo de ciclo otto com uma distribuição normal padrão.

APÊNDICE 2: Testes Estatísticos do Modelo VECM

Tabela 28: Teste de duas raízes unitárias de Dickey-Pantula para série de preço médio do ciclo otto.

Conclusão do teste Dickey-Pantula	Tipo de Teste	Valor do Teste	Critical Value (5%)
n° de raízes unitárias < 2	Sem termos deterministas	-9.1702	-3.4333
n° de raízes unitárias < 2	Com constante	-9.1500	-3.4334
n° de raízes unitárias < 2	Com tendência e constante	-9.1287	-3.4335

Tabela 29: Teste de raiz unitária DF-GLS para série de preço médio do ciclo otto.

Conclusão do teste DF-GLS	Tipo de Teste	Valor do Teste	Critical Value (5%)
Não estacionário	Com tendência	-1.9387	-2.93
Não estacionário	Com constante	-1.111	-1.94

Tabela 30: Teste de raiz unitária KPSS para série de preço médio do ciclo otto.

Conclusão do teste KPSS	Tipo de Teste	Test Value	Critical Value (5%)
Não estacionário	Com constante	1.029	0.463
Não estacionário	Com tendência e constante	0.1976	0.146

Tabela 31: Teste de raiz unitária sazonal OCSB para série de preço médio do ciclo otto.

Conclusão do teste OCSB	Test Value	Critical Value (5%)
Não possui raiz unitária sazonal	-14.1002	-1.803

Tabela 32: Teste de duas raízes unitárias de Dickey-Pantula para série de PIB per capita.

Conclusão do teste Dickey-Pantula	Tipo de Teste	Valor do Teste	Critical Value (5%)
n° de raízes unitárias > 2	Sem termos deterministas	-3.1210	-3.4333
n° de raízes unitárias < 2	Com constante	-3.6393	-3.4334
n° de raízes unitárias < 2	Com tendência e constante	-4.2924	-3.4335

Tabela 33: Teste de raiz unitária DF-GLS para série de PIB per capita.

Conclusão do teste DF-GLS	Tipo de Teste	Valor do Teste	Critical Value (5%)
Não estacionário	Com tendência	-0.5627	-2.93
Não estacionário	Com constante	0.4032	-1.94

Tabela 34: Teste de raiz unitária KPSS para série de PIB per capita.

Conclusão do teste KPSS	Tipo de Teste	Test Value	Critical Value (5%)
Não estacionário	Com constante	1.2468	0.463
Não estacionário	Com tendência e constante	0.3007	0.146

Tabela 35: Teste de raiz unitária sazonal OCSB para série de PIB per capita.

Conclusão do teste OCSB	Test Value	Critical Value (5%)
Não possui raiz unitária sazonal	-4.1836	-1.803

Tabela 36: Teste de cointegração de máximo autovalor de Johansen.

Hipótese nula do teste do máximo autovalor	Test Value	Critical Value (5%)
$r \leq 2$	5.53	9.24
$r \leq 1$	13.75	15.67
$r = 0$	186.92	22.00

Tabela 37: Teste de cointegração do traço de Johansen.

Hipótese nula do teste do traço	Test Value	Critical Value (5%)
$r \leq 2$	5.53	9.24
$r \leq 1$	19.28	19.96
$r = 0$	206.20	34.91

Tabela 38: Teste de autocorrelação multivariada dos resíduos de Edgerton-Shukur.

Conclusão do teste Edgerton-Shukur (IC=5%)	p-valor	Número de defasagens para ajuste do teste
Não há autocorrelação.	0,9652	2
Não há autocorrelação.	0,8031	4
Não há autocorrelação.	0,258	6

Tabela 39: Teste de autocorrelação multivariada dos resíduos de Portmanteau.

Conclusão do teste de Portmanteau (IC=5%)	p-valor	Número de defasagens para ajuste do teste
Há autocorrelação.	0,0022	6
Não há autocorrelação.	0,0629	12
Não há autocorrelação.	0,1542	18

Tabela 40: Teste de normalidade dos resíduos de Jarque-Bera.

Conclusão do teste de normalidade Jarque-Bera (IC=5%)	p-valor	Série testada
Não normalmente distribuídos.	2,138e-06	Consumo
Não normalmente distribuídos.	8,151e-13	Preço
Não normalmente distribuídos.	1,109e-06	PIB per capita
Não normalmente distribuídos.	2,200e-16	Multivariado

Tabela 41: Teste de normalidade dos resíduos de Shapiro-Wilk.

Conclusão do teste de normalidade Shapiro-Wilk (IC=5%)	p-valor	Série testada
Não normalmente distribuídos.	1,24e-2	Consumo
Não normalmente distribuídos.	1,15e-6	Preço
Não normalmente distribuídos.	8,17e-3	PIB per capita
Não normalmente distribuídos.	9,58e-4	Multivariado

Tabela 42: Teste LM de heterocedasticidade condicional dos resíduos.

Conclusão do teste de heterocedasticidade LM (IC=5%)	Série testada	Número de defasagens para ajuste do teste
São homocedásticos.	Consumo	2, 5, 12, 18
São homocedásticos.	Preço	2, 5, 12, 18
São homocedásticos.	PIB per capita	2, 4, 6, 12, 18
Não são homocedásticos.	Multivariado	2, 4, 6, 12, 18




Figura 28: Comparação da frequência dos resíduos do modelo VECM de consumo de ciclo otto com uma distribuição normal padrão.




Figura 29: Comparação da frequência dos resíduos do modelo VECM de preço médio de ciclo otto com uma distribuição normal padrão.




Figura 30: Comparação da frequência dos resíduos do modelo VECM de PIB per capita com uma distribuição normal padrão.

APÊNDICE 3: Evolução do MAPE dos modelos

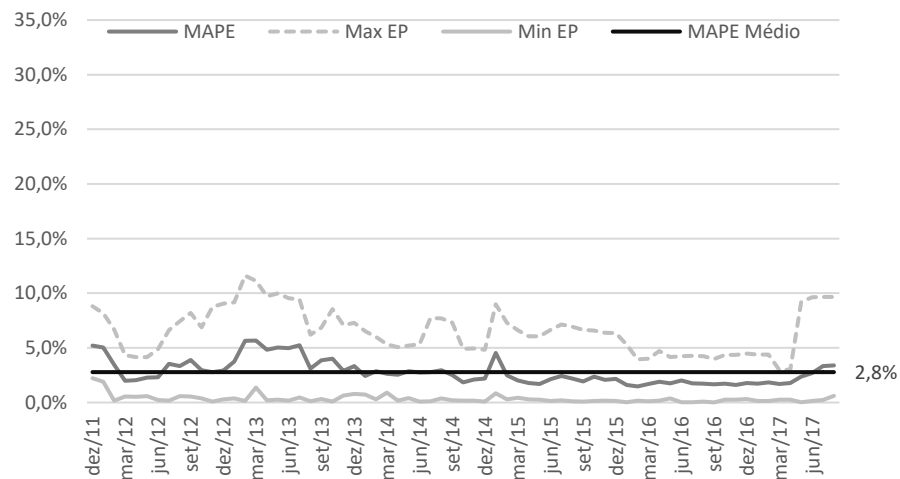


Figura 31: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SVM para previsão de 12 meses.

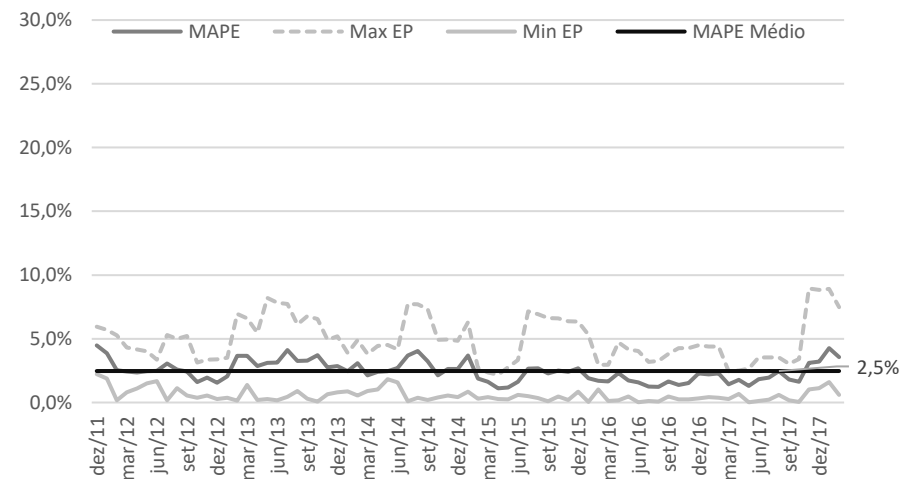


Figura 32: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SVM para previsão de 6 meses.




Figura 33: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SVM para previsão de 3 meses.




Figura 34: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo VECM para previsão de 12 meses.




Figura 35: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo VECM para previsão de 6 meses.




Figura 36: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo VECM para previsão de 3 meses.




Figura 37: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR.Bin para previsão de 12 meses.




Figura 38: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR.Bin para previsão de 6 meses.




Figura 39: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR.Bin para previsão de 3 meses.




Figura 40: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo ANN para previsão de 12 meses.




Figura 41: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo ANN para previsão de 6 meses.




Figura 42: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo ANN para previsão de 3 meses.




Figura 43: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo RF para previsão de 12 meses.




Figura 44: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo RF para previsão de 6 meses.




Figura 45: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo RF para previsão de 3 meses.




Figura 46: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HYFIS para previsão de 12 meses.




Figura 47: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HYFIS para previsão de 6 meses.




Figura 48: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HYFIS para previsão de 3 meses.




Figura 49: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR para previsão de 12 meses.




Figura 50: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR para previsão de 6 meses.




Figura 51: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo SAR para previsão de 3 meses.




Figura 52: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo GM para previsão de 12 meses.




Figura 53: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo GM para previsão de 6 meses.




Figura 54: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo GM para previsão de 3 meses.




Figura 55: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo STL para previsão de 12 meses.




Figura 56: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo STL para previsão de 6 meses.




Figura 57: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo STL para previsão de 3 meses.




Figura 58: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HM para previsão de 12 meses.




Figura 59: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HM para previsão de 6 meses.




Figura 60: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo HM para previsão de 3 meses.




Figura 61: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo DLM para previsão de 12 meses.




Figura 62: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo DLM para previsão de 6 meses.




Figura 63: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo DLM para previsão de 3 meses.




Figura 64: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MANN para previsão de 12 meses.




Figura 65: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MANN para previsão de 6 meses.




Figura 66: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MANN para previsão de 3 meses.




Figura 67: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo Seas Naive para previsão de 12 meses.




Figura 68: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo Seas Naive para previsão de 6 meses.




Figura 69: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo Seas Naive para previsão de 3 meses.




Figura 70: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MQO para previsão de 12 meses.




Figura 71: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MQO para previsão de 6 meses.




Figura 72: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MQO para previsão de 3 meses.




Figura 73: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MED para previsão de 12 meses.




Figura 74: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MED para previsão de 6 meses.




Figura 75: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo MED para previsão de 3 meses.




Figura 76: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo PC para previsão de 12 meses.




Figura 77: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo PC para previsão de 6 meses.




Figura 78: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo PC para previsão de 3 meses.




Figura 79: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo FA para previsão de 12 meses.




Figura 80: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo FA para previsão de 6 meses.




Figura 81: MAPE, MAPE Médio e máximo e mínimo erro absoluto percentual do modelo FA para previsão de 3 meses.

APÊNDICE 4: Evolução do MAPE dos modelos SVM, VECM, SAR.Bin e combinados dentro da amostra de treinamento





Figura 82: MAPE e MAPE Médio do modelo SVM dentro da amostra de treinamento para previsão de 12 meses.

Figura 83: MAPE e MAPE Médio do modelo SVM dentro da amostra de treinamento para previsão de 6 meses.




Figura 84: MAPE e MAPE Médio do modelo SVM dentro da amostra de treinamento para previsão de 3 meses.




Figura 85: MAPE e MAPE Médio do modelo VECM dentro da amostra de treinamento para previsão de 12 meses.




Figura 86: MAPE e MAPE Médio do modelo VECM dentro da amostra de treinamento para previsão de 6 meses.




Figura 87: MAPE e MAPE Médio do modelo VECM dentro da amostra de treinamento para previsão de 3 meses.




Figura 88: MAPE e MAPE Médio do modelo SAR.Bin dentro da amostra de treinamento para previsão de 12 meses.




Figura 89: MAPE e MAPE Médio do modelo SAR.Bin dentro da amostra de treinamento para previsão de 6 meses.




Figura 90: MAPE e MAPE Médio do modelo SAR.Bin dentro da amostra de treinamento para previsão de 3 meses.




Figura 91: MAPE e MAPE Médio do modelo MQO dentro da amostra de treinamento para previsão de 12 meses.




Figura 92: MAPE e MAPE Médio do modelo MQO dentro da amostra de treinamento para previsão de 6 meses.




Figura 93: MAPE e MAPE Médio do modelo MQO dentro da amostra de treinamento para previsão de 3 meses.




Figura 94: MAPE e MAPE Médio do modelo MED dentro da amostra de treinamento para previsão de 12 meses.




Figura 95: MAPE e MAPE Médio do modelo MED dentro da amostra de treinamento para previsão de 6 meses.




Figura 96: MAPE e MAPE Médio do modelo MED dentro da amostra de treinamento para previsão de 3 meses.




Figura 97: MAPE e MAPE Médio do modelo PC dentro da amostra de treinamento para previsão de 12 meses.




Figura 98: MAPE e MAPE Médio do modelo PC dentro da amostra de treinamento para previsão de 6 meses.




Figura 99: MAPE e MAPE Médio do modelo PC dentro da amostra de treinamento para previsão de 3 meses.




Figura 100: MAPE e MAPE Médio do modelo FA dentro da amostra de treinamento para previsão de 12 meses.




Figura 101: MAPE e MAPE Médio do modelo FA dentro da amostra de treinamento para previsão de 6 meses.




Figura 102: MAPE e MAPE Médio do modelo FA dentro da amostra de treinamento para previsão de 3 meses.