

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**  
**DEPARTAMENTO DE ENGENHARIA DE PRODUÇÃO**  
**ENGENHARIA DE PRODUÇÃO**

**GABRIELA COSTA SLOMPO**  
**GUSTAVO CAMPOS MORETTIN**

**PREVISÃO POR MODELOS DE SÉRIES TEMPORAIS DO**  
**LICENCIAMENTO DE VEÍCULOS ELÉTRICOS NO BRASIL**

**TRABALHO DE CONCLUSÃO DE CURSO**

**PONTA GROSSA**

**2021**

**GABRIELA COSTA SLOMPO**  
**GUSTAVO CAMPOS MORETTIN**

**PREVISÃO POR MODELOS DE SÉRIES TEMPORAIS DO  
LICENCIAMENTO DE VEÍCULOS ELÉTRICOS NO BRASIL**

**Forecasting by time series models for the electric vehicle licensing in Brazil**

Trabalho de conclusão de curso de graduação apresentado como requisito para obtenção do título de Bacharel em Engenharia de Produção da Universidade Tecnológica Federal do Paraná (UTFPR).

Orientadora: Prof<sup>ª</sup>. Dr<sup>ª</sup>. Yslene Rocha Kachba.



**PONTA GROSSA**

**2021**



[4.0 Internacional](https://creativecommons.org/licenses/by-nc-sa/4.0/)

Esta licença permite remixe, adaptação e criação a partir do trabalho, para fins não comerciais, desde que sejam atribuídos créditos ao(s) autor(es) e que licenciem as novas criações sob termos idênticos. Conteúdos elaborados por terceiros, citados e referenciados nesta obra não são cobertos pela licença.

	<b>Ministério da Educação</b> <b>UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ</b> <b>CÂMPUS PONTA GROSSA</b> Departamento Acadêmico de Engenharia de Produção	 <small>UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ</small>
---	--	--

TERMO DE APROVAÇÃO DE TCC

**PREVISÃO POR MODELOS DE SÉRIES TEMPORAIS DO LICENCIAMENTO DE VEÍCULOS ELÉTRICOS NO BRASIL**

por

**Gabriela Costa Slompo e Gustavo Campos Morettin**

Este Trabalho de Conclusão de Curso (TCC) foi apresentado em quatro de maio de 2021 como requisito parcial para a obtenção do título de Bacharel em Engenharia de Produção. O(A)(s) candidato(a)(s) foi(foram) arguido(a)(s) pela Banca Examinadora composta pelos professores abaixo assinados. Após deliberação, a Banca Examinadora considerou o trabalho aprovado.

---

*Prof. Dr(a). Yslene Rocha Kachba*  
Prof. Orientador(a)

---

*Prof. Dr(a). Everton Luiz de Melo*  
Membro titular

---

*Prof. Dr(a). Fabio Jose Ceron Branco*  
Membro titular

- O Termo de Aprovação assinado encontra-se na Coordenação do Curso -

## RESUMO

SLOMPO, Gabriela Costa; MORETTIN, Gustavo Campos. **Previsão por modelos de séries temporais do licenciamento de veículos elétricos no Brasil**. 2021. 63 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Produção) - Universidade Tecnológica Federal do Paraná. Ponta Grossa, 2021.

A preocupação com questões ambientais é recorrente há anos, mas os impactos ambientais de cada ação têm se tornado uma preocupação maior somente nos últimos anos. O papel de empresas que abraçam essa causa é buscar por alternativas a seus produtos ou serviços que gerem o menor impacto possível sem comprometer a qualidade do que é oferecido. No setor automobilístico, uma considerável alternativa é a produção de veículos elétricos, que funcionam através de energia elétrica e abandonam os motores à combustão. Nesse tipo de veículo, o funcionamento se dá com a utilização de energia elétrica que é armazenada em uma bateria, diferente dos veículos tradicionais, que são movidos com a queima de ar e combustíveis, resultando na emissão atmosférica de gases como CO, CO<sub>2</sub>, HC, O<sub>3</sub>, SO<sub>2</sub>, NO<sub>x</sub> e Material Particulado. Essa mudança na estrutura dos veículos elimina a emissão de gases durante o funcionamento dos automóveis, o que reduz os impactos ambientais que eles causam diariamente. Utilizando o modelo ARIMA(0,1,1), foi previsto o número de veículos elétricos licenciados no Brasil. Para isso, foram utilizados dados de licenciamento de outros tipos de veículos automobilísticos na produção de combustíveis e na quantidade de emissão veicular de CO<sub>2</sub>. A previsão mostra que haverá um crescimento de veículos elétricos licenciados no país, mesmo com a queda causada durante a pandemia do Covid-19. Essa previsão indica que o mercado brasileiro de veículos elétricos será capaz de se recuperar e superar os danos sofridos na pandemia. Esse cenário valida a eficácia do Projeto Rota 2030 até o ano de 2025.

**Palavras-chave:** Métodos de previsão. Veículos elétricos. Projeto Rota 2030.

## ABSTRACT

SLOMPO, Gabriela Costa; MORETTIN, Gustavo Campos. 2021. **Forecasting by time series models for the electric vehicle licensing in Brazil.** 63 p. Work of Conclusion Course (Graduation in Production Engineering) - Federal Technology University - Paraná. Ponta Grossa, 2021.

The concern about environmental issues has been recurring for years, but the environmental impacts of each action have become a major concern only in the past few years. The role of companies that embrace this cause is to search for alternatives to their products or services that cause the least impact as possible without compromising the quality of what is offered. In the automotive sector, a considerable alternative is the production of electric vehicles, which operate through electric power and abandon the combustion engines. In this type of vehicle, its operation occurs with the use of electric energy that is stored in a battery, different from traditional vehicles, which are moved by the combustion of air and fuels, resulting in the atmospheric emission of gases such as CO, CO<sub>2</sub>, HC, O<sub>3</sub>, SO<sub>2</sub>, NO<sub>x</sub> and Particulate Matter. This change in the vehicles structure eliminates the emission of gases during the automobiles' operation, which reduces the environmental impacts that they cause on a daily basis. Using the ARIMA(0,1,1) model, the number of electric vehicles licensed in Brazil was forecasted based on licensing data for other types of automobile vehicles, on the fuels production, and on the amount of vehicle CO<sub>2</sub>. The forecast shows that there was a growth in electric vehicles licensed in the country, even with the drop caused during the Covid-19 pandemic. This forecast indicates that the Brazilian electric vehicle market will be able to recover and overcome the damage suffered in the pandemic. This scenario validates the effectiveness of the Rota 2030 Project until the year 2025.

**Keywords:** Forecasting methods. Electric vehicles. Rota 2030 project.

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>8</b>
1.1 PROBLEMÁTICA .....	9
1.2 JUSTIFICATIVA .....	9
1.3 OBJETIVOS .....	10
1.3.1 Objetivo geral .....	10
1.3.2 Objetivos específicos .....	10
1.4 DELIMITAÇÃO DO TEMA .....	11
<b>2 REFERENCIAL TEÓRICO</b> .....	<b>12</b>
2.1 HISTÓRIA DOS AUTOMÓVEIS .....	12
2.2 FUNCIONAMENTO DOS VEÍCULOS .....	14
2.2.1 Veículos com motor a combustão interna .....	15
2.2.2 Veículos biocombustíveis .....	16
2.2.3 Veículos com motor diesel .....	17
2.2.4 Veículos elétricos .....	17
2.2.5 Veículos híbridos .....	19
2.3 PROJETO ROTA 2030 .....	19
2.4 PANDEMIA DO CORONAVÍRUS .....	21
2.5 ESTUDO DE PREVISÕES A PARTIR DE SÉRIES TEMPORAIS .....	22
2.5.1 Séries temporais .....	22
2.6 ANÁLISE ESTATÍSTICA .....	23
2.6.1 Regressão Linear .....	24
2.6.2 Equação da Reta .....	24
2.6.3 Sazonalidade .....	25
2.6.4 Tipos de Erro .....	25
2.6.4.1 Raiz do Erro Quadrático Médio (RMSE) .....	25
2.6.4.2 Erro Médio Absoluto (MAE) .....	26
2.6.4.3 Critério de Informação de Akaike (AIC) .....	26
2.7 MÉTODOS DE PREVISÃO .....	27
2.7.1 Métodos paramétricos .....	28
2.7.1.1 Modelo de Média Móvel .....	28
2.7.1.2 Modelo SE .....	29
2.7.1.3 Modelo AR .....	29
2.7.1.4 Modelo ARMA .....	30
2.7.1.5 Modelo ARIMA .....	30
2.7.1.6 Modelo ARCH .....	31
2.7.2 Métodos não paramétricos .....	31
2.7.2.1 Redes Neurais Artificiais .....	32
2.7.2.2 Redes <i>Multilayer Perceptron</i> (MLP) .....	33

<b>3 METODOLOGIA.....</b>	<b>36</b>
3.1 CLASSIFICAÇÃO DA PESQUISA .....	36
3.1.1 Natureza da pesquisa .....	36
3.1.2 Abordagem .....	36
3.1.3 Objetivos .....	37
3.1.4 Procedimentos .....	37
3.2 ETAPAS DO DESENVOLVIMENTO.....	37
3.2.1 Fundamentação do estudo .....	38
3.2.2 Levantamento de dados .....	38
3.2.2.1 Licenciamento de veículos elétricos (Y) .....	39
3.2.2.2 Veículos licenciados com base no tipo de motor.....	39
3.2.2.3 Quantidade de combustível produzido .....	39
3.2.2.4 Emissão de CO <sub>2</sub> (X).....	39
3.2.3 Escolha do método .....	41
3.2.3.1 Estudo de correlação.....	41
3.2.3.3 Aplicação do método.....	42
<b>4 RESULTADOS E DISCUSSÃO .....</b>	<b>43</b>
4.1 PREVISÃO DAS VARIÁVEIS INDEPENDENTES .....	43
4.2 PREVISÃO DA VARIÁVEL DEPENDENTE.....	49
4.2.1 Estudo estatístico.....	49
4.2.2 Previsão do licenciamento dos veículos elétricos .....	50
<b>5 CONCLUSÃO.....</b>	<b>53</b>
<b>REFERÊNCIAS.....</b>	<b>54</b>

## 1 INTRODUÇÃO

Foi Alberto Santos Dumont (1873-1932) quem trouxe os primeiros veículos para as terras brasileiras. Famoso por ser um dos pioneiros na aviação, Dumont foi enviado à Europa para se inteirar das novas tecnologias mundiais, e assim teve seu primeiro contato com o transporte de quatro rodas, adquirindo seu primeiro carro em 1890. Em 1891, ao retornar ao Brasil, desembarcou com o carro no Porto de Santos, um Peugeot, que logo atraiu a atenção da elite do país (MELO, 2008).

Apesar do automóvel ter chegado no Brasil no século XIX, a produção no país só teve início no século seguinte, com a instalação de linhas de montagem da Ford (1919), da General Motors (1924) e da International Harvester (1926) (GUIMARÃES, 1980). De acordo com Azuaga (2000), a indústria automobilística foi oficialmente instalada no Brasil no governo de Juscelino Kubitschek, em 1957, produzindo veículos de três categoriais: automóveis, comerciais leves e comerciais pesados.

Com o avanço da globalização, a utilização de automóveis movidos a combustão se tornou cada vez mais necessária no cotidiano das pessoas, contudo, uma grande quantidade de veículos em circulação implica em uma maior quantidade de gases poluentes emitidos na atmosfera. Ao serem emitidos, esses gases resultam em diversos problemas ao meio ambiente e à saúde dos seres humanos.

Dentre os efeitos prejudiciais ao meio ambiente estão o aquecimento global, a geração de chuvas ácidas e o aumento da intensidade de raios ultravioleta, gerada pela debilitação da camada de ozônio. Em relação à saúde, ao entrar em contato com o corpo humano estes gases causam problemas que estão relacionados a doenças respiratórias (asma, bronquite, etc.), irritação nos olhos, aumento da vulnerabilidade a infecções virais, dores de cabeça, etc (ALMEIDA, 1999).

Uma alternativa que busca atuar diretamente na diminuição da poluição é o uso de veículos elétricos, que não realizam a queima de combustíveis. O Projeto Rota 2030, em vigor no Brasil desde 2018 e com horizonte até 2030, incentiva a Pesquisa e Desenvolvimento de tecnologias que viabilizam a produção e promovem o uso desses veículos no país.

No ano de 2020, dentro do horizonte do projeto, chegou no Brasil a pandemia do coronavírus, que afetou a economia mundial, impactando diretamente o setor automobilístico.



Levando em conta esse cenário atual brasileiro, um estudo de previsão a partir de séries temporais será necessário para reconhecer a eficácia do Projeto Rota 2030, desde sua implementação até o ano de 2025, considerando a pandemia do coronavírus e o avanço da tecnologia no setor automobilístico.

## 1.1 PROBLEMÁTICA

Com o cenário atual brasileiro que promove incentivos a Pesquisa e Desenvolvimento de novas tecnologias para veículos menos poluentes, incluindo veículos com motores elétricos, somado a preocupação ambiental em reduzir emissões atmosféricas, o presente trabalho busca analisar como tal cenário impactará no licenciamento de veículos elétricos no Brasil.

## 1.2 JUSTIFICATIVA

O tema da pesquisa está incluso em duas diferentes áreas da Engenharia de Produção, sendo elas a Pesquisa Operacional (PO) e a Logística. O fato de o presente trabalho atuar nestas duas diferentes áreas torna evidente a sua relação direta com o curso de Engenharia de Produção.

A PO está relacionada com o método a ser utilizado, que trabalha com modelagens matemáticas através de meios computacionais para se obter resultados. A área da Logística está inserida no estudo a partir do momento em que se trata do transporte rodoviário brasileiro.

Além de estar relacionado diretamente com a Engenharia de Produção, o tema do trabalho é de grande importância em sua área de atuação. Sua relevância é reforçada por se tratar de um tema ainda pouco explorado em relação à literatura mundial, apesar do emergente mercado de veículos elétricos, que atualmente apresenta desenvolvimento de novos modelos e políticas de incentivo ao uso e recarga dos veículos.

O foco em veículos elétricos também se deve as atuais preocupações ambientais, à vista que esse meio de transporte é uma das principais alternativas a

utilização de veículos a combustão. Tendo isso em mente, o foco da pesquisa é estudar a correlação do licenciamento de veículos elétricos com a produção de combustíveis, o licenciamento de veículos por tipo de motor e a emissão veicular de CO<sub>2</sub>.

A aprovação da lei que incentiva o consumo de veículos que utiliza energia renovável no país é traçada até o ano 2030, por isso o título “Rota 2030”. O horizonte da previsão realizada no presente trabalho é o ano 2025, sendo possível fazer uma análise da influência do projeto nesse período de tempo.

### 1.3 OBJETIVOS

Neste tópico são apresentados o objetivo geral e os objetivos específicos que dão seguimento ao trabalho.

#### 1.3.1 Objetivo geral

O objetivo geral do estudo é prever o licenciamento de veículos elétricos no Brasil até 2025, com base em fatores externos que incentivam a adoção deste meio de transporte, a fim de estimar o impacto causado em função destes fatores.

#### 1.3.2 Objetivos específicos

Para alcançar o objetivo geral, a pesquisa tem como objetivos específicos:

- definir os métodos de previsão adequados para resolução do problema;
- identificar os dados relacionados com o problema e coletá-los conforme disponibilidade;
- aplicar os métodos elencados para fazer a previsão do licenciamento de veículos elétricos no Brasil;
- avaliar os resultados das previsões e selecionar a melhor previsão;
- validar o impacto das medidas impostas pelo governo e o avanço da tecnologia em relação a quantidade de veículos elétricos licenciados no país.

#### 1.4 DELIMITAÇÃO DO TEMA

Levando em consideração uma frota rodoviária com uma infinidade de modelos diferentes de automóveis, torna-se inviável a utilização de dados precisos no cálculo das variáveis, já que os diferentes modelos de carro apresentam uma média de consumo de combustíveis diferentes, sendo necessária a utilização de uma média geral para lidar com esse tipo de dado.

Ao realizar a pesquisa no Brasil como um todo, é necessário levar em consideração que não será possível representar toda a área estudada homogeneamente, pois as emissões de gases se concentram nas maiores áreas urbanas do país, além de que não existem estações de coleta de dados mensais em todas as unidades da federação brasileira.

Outra delimitação do tema está em relação à escolha de apenas um gás ( $\text{CO}_2$ ) para compor a base de dados das variáveis independentes, não levando em conta assim os demais gases emitidos pelos motores a combustão.

A coleta de dados é limitada até o período final da coleta, não considerando os valores futuros das variáveis independentes, desta forma, torna-se necessário a previsão individual das variáveis independentes para poder preencher as amostras faltantes da base de dados.

As metodologias de previsão apresentadas neste estudo necessitam de *softwares* para realizar o processamento dos dados, os quais nem sempre são fáceis de serem encontrados ou então apresentam plataformas de trabalho não compatíveis com a base de dados.

## 2 REFERENCIAL TEÓRICO

O presente capítulo é dividido em seis diferentes seções, tendo como principal objetivo apresentar os principais conceitos que são abordados neste trabalho, proporcionando assim um maior entendimento ao leitor.

As sessões apresentadas a seguir estão separadas em diferentes propósitos, sendo eles: uma introdução sobre a história dos automóveis; o funcionamento dos veículos com base no tipo de motor; a explicação do projeto Rota 2030; uma breve apresentação do conceito de séries temporais; o levantamento dos métodos de previsão que podem ser utilizados; e por fim, uma exploração na literatura com o objetivo de identificar a intensidade de pesquisas relacionadas nesta mesma área.

### 2.1 HISTÓRIA DOS AUTOMÓVEIS

Das invenções do último milênio, os automóveis podem ser considerados uma das mais importantes e que sofreram grande evolução. O primeiro veículo não teve somente um criador numa data específica, mas é fruto de uma evolução e de diversas tentativas em contextos históricos distintos.

A necessidade de outros meios de locomoção, além do próprio caminhar, surgiu no transporte de bens e cargas a longas distâncias. Sempre buscando transportar cargas mais pesadas para maiores distâncias, o homem percebeu que poderia utilizar a força de animais domésticos como ajuda, então, implementou carroças puxadas por bois e outros animais mais fortes, e com a invenção da roda, pôde criar carruagens puxadas a cavalo, que se tornaram mais populares com o aumento das estradas. Com a Revolução Industrial (1760-1830), o primeiro automóvel pôde ser fabricado devido a criação do motor a combustão interna (FRANZ; SEBERINO, 2012).

Além dos veículos movidos a combustão, no final do século XIX também já se produziam veículos elétricos, por efeito da criação da primeira bateria chumbo-ácido por Gaston Planté, em 1859. Com o emprego dessa bateria, os primeiros veículos elétricos foram desenvolvidos a partir de 1880 nos EUA, Reino Unido e França. Assim, através do decorrente crescimento da indústria automobilística para carros elétricos,

a combustão e a vapor, em 1899 nos Estados Unidos foi registrada a venda de 1581 automóveis a vapor, 1575 elétricos e 936 a combustão (gasolina) (BRAN, 2012).

As tecnologias para o funcionamento de veículos que já se popularizaram no final do século XIX são as três principais dentre todos os veículos produzidos durante a história: vapor, combustão e elétricos. Todos os tipos apresentaram problemas técnicos durante o desenvolvimento, mas os fabricantes de veículos movidos a combustão obtiveram melhores soluções para seus produtos e desta forma conseguiram se destacar e predominar o mercado automotivo (BRAN, 2012).

A produção de veículos automotores a combustão, que em 1899 era a menor das três modalidades, só tomou frente após a Primeira Guerra Mundial, nos Estados Unidos, quando deixou de ser uma produção artesanal e passou a ser em massa. Os condutores dessa transformação foram Alfred Sloan (da General Motors) e Henry Ford. Depois da Segunda Guerra Mundial, quem tomou frente nesse ramo foram os japoneses com o conceito de produção enxuta, graças a Eiji Toyoda e Taiichi Ohno, da empresa Toyota (WOMACK; JONES; ROOS, 2004).

Ao passar dos anos, a preocupação com o meio ambiente tornou-se algo presente na realidade das indústrias mundialmente, e como os veículos emitem gases atmosféricos prejudiciais ao meio ambiente e à saúde do homem, surgiu o questionamento se automóveis movidos a combustão são realmente a melhor alternativa, considerando os impactos ambientais causados por eles (BRAN; LEGEY, 2010).

A partir da década de 1970, com questões ambientais em alta e com a Crise do Petróleo (1973), programas que buscam a redução do consumo de energia e desenvolvimento sustentável foram sendo desenvolvidos no mundo todo, como normas regulatórias de zero emissão implementadas em 1990 na Califórnia (EUA) e o plano de ação Agenda 21, que na conferência Rio-92 (1992) discutiu as consequências a longo prazo do uso excessivo de energia fóssil. Essas pautas influenciaram na preocupação em reduzir a combustão nos veículos, o que aumentou a busca por alternativas como os próprios veículos elétricos ou híbridos (BRAN; LEGEY, 2010).

Ademais da preocupação ambiental, também leva-se em conta a preocupação com as doenças causadas pelo excesso da poluição, sendo que cada poluente gera um efeito diferente na saúde humana. O CO, ao entrar em contato com o organismo, reduz a oxigenação do sangue, causando náuseas e intoxicação. O NO<sub>x</sub>

é responsável por problemas respiratórios, já o  $\text{SO}_x$  provoca irritação nos olhos, além de problemas cardiovasculares e respiratórios. O Material particulado (MP) não é um gás, mas se também penetrado nas defesas dos organismos, atinge os alvéolos pulmonares e então causa bronquite, asma e até câncer nos pulmões. Por fim, o  $\text{O}_3$  gera irritação nos olhos e uma irritação inflamatória nas vias aéreas (DRUMM et al, 2014).

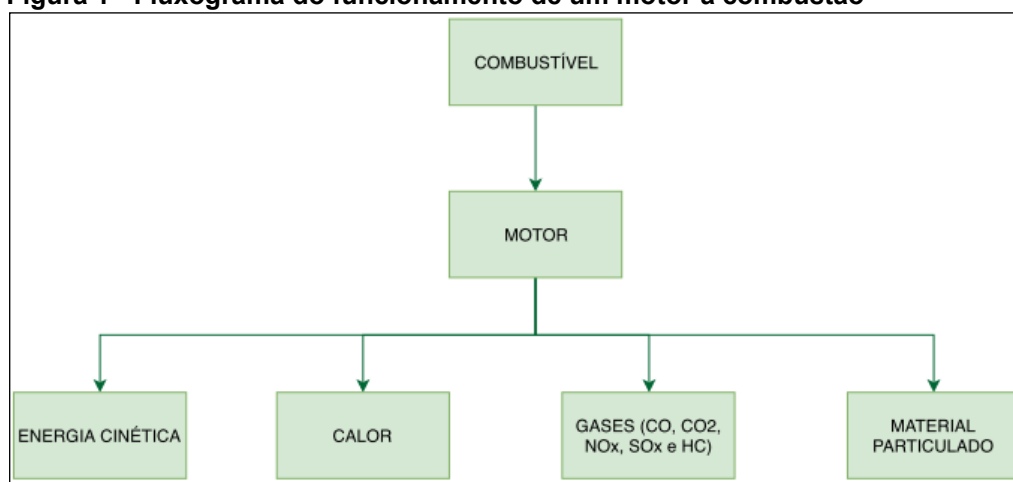
## 2.2 FUNCIONAMENTO DOS VEÍCULOS

O funcionamento do principal tipo de veículo comercializado acontece através da queima de combustíveis fósseis, que são substâncias naturais não renováveis de origem mineral, como gasolina e diesel. Essas substâncias são compostas de carbono, formadas com a decomposição de materiais orgânicos. Ao serem emitidas na atmosfera, lançam gases como o gás carbônico ( $\text{CO}_2$ ), que é um grande responsável pelo aquecimento global e pelo efeito estufa (DRUMM et al, 2014).

Os combustíveis utilizados no funcionamento dos automóveis dependem da matriz energética brasileira, que define quais fontes de energia podem ser empregadas na realização de qualquer atividade no país. Para o transporte terrestre de passageiros, a legislação permite o uso de três tipos de combustível: gasolina, etanol e gás natural veicular. O óleo diesel é aplicado a veículos de maior carga, sendo os principais ônibus, caminhões, camionetas (NOCE, 2009).

Comparado com países como os Estados Unidos, o Brasil é responsável por uma baixa emissão de dióxido de carbono proveniente do consumo de energia elétrica, podendo até se considerar que o país conta com uma matriz elétrica limpa. Porém, as fontes de energia utilizadas para o transporte no Brasil são poluentes, como os combustíveis líquidos fósseis e biomassa. Uma alternativa é a utilização de Gás Natural Veicular (GNV), porém esse combustível também emite gases do efeito estufa ao ser queimado (NOCE, 2009).

**Figura 1 - Fluxograma do funcionamento de um motor a combustão**



**Fonte: Autoria própria, 2019.**


Para o funcionamento de veículos automotores a combustão, esquematizado no fluxograma da Figura 1, diversas substâncias tóxicas são liberadas na atmosfera devido à queima incompleta de combustíveis, como: óxido e dióxido de carbono (CO e CO<sub>2</sub>), óxido de nitrogênio (NO<sub>x</sub>), hidrocarbonetos (HC), óxido de enxofre (SO<sub>x</sub>), Material Particulado (MP), entre outras (TEIXEIRA; FELTES; SANTANA, 2008).

### 2.2.1 Veículos com motor a combustão interna

A maior parte dos veículos que utilizam gasolina como combustível funcionam através de um motor de combustão interna, também chamado de “motor de quatro tempos”, pois tem uma sequência de quatro estágios: admissão; compressão; expansão; e exaustão. A sequência, conhecida como ciclo de Otto está esquematizada na Figura 2 (PEREIRA, 2015).

A admissão inicia com uma mistura de ar e combustível que é aspirada ao interior do cilindro, com uma válvula de admissão aberta e uma de descarga fechada, quando um pistão é deslocado de um ponto superior do cilindro a um inferior, empurrando junto a mistura ao inferior. A compressão ocorre com a subida do pistão, que comprime a mistura de ar-combustível. Assim, a expansão acontece com a explosão da mistura, consequência de uma chama responsável pela queima do combustível, empurrando assim o pistão para baixo. Na exaustão, com a válvula de admissão fechada, a válvula de exaustão abre, o pistão sobe e libera os gases queimados na expansão para o escapamento do veículo (SOUZA, 2004).

**Figura 2 - Sequência de quatro tempos do ciclo de Otto**



Fonte: Pereira, 2015.

Os produtos de uma queima ideal de gasolina em um motor a combustão interna seriam apenas água e gás carbônico, porém, esse processo não acontece de forma ideal, seja pela ineficiência do motor ou pela composição da mistura de ar-combustível. Dessa forma, a reação também emite substâncias como Óxido de Carbono, Óxido de Nitrogênio, Hidrocarbonetos não queimados, MP, benzeno (agente cancerígeno) e até óxidos de enxofre ( $\text{SO}_2$ ) pelo enxofre que contém na gasolina (DRUMM et al, 2014).

### 2.2.2 Veículos biocombustíveis

Na busca por combustíveis alternativos e maior flexibilidade, nascem os veículos *Flex Fuel*, também chamados de bicombustíveis. A tecnologia desses veículos é resultado de pesquisas realizadas no final dos anos 80 nos Estados Unidos, Japão e países da Europa. Buscando por uma solução à falta de infraestrutura para abastecer veículos a álcool, criou-se um sistema que possibilita o funcionamento de veículos utilizando álcool, gasolina e diferentes misturas entre esses dois tipos de combustível (SIQUEIRA; SIQUEIRA, 2004).

O desempenho dos bicombustíveis é através de um motor com componentes e sensores que conseguem adaptar seu funcionamento a qualquer quantidade de álcool e gasolina contida no tanque. A base do motor é semelhante à convencional,



que também opera no ciclo de Otto, mas este tipo de motor foi desenvolvido de forma a reconhecer, se adaptar e ser mais resistente a diferentes tipos de combustível, como evitar corrosões causadas pelo álcool (SIQUEIRA; SIQUEIRA, 2004).

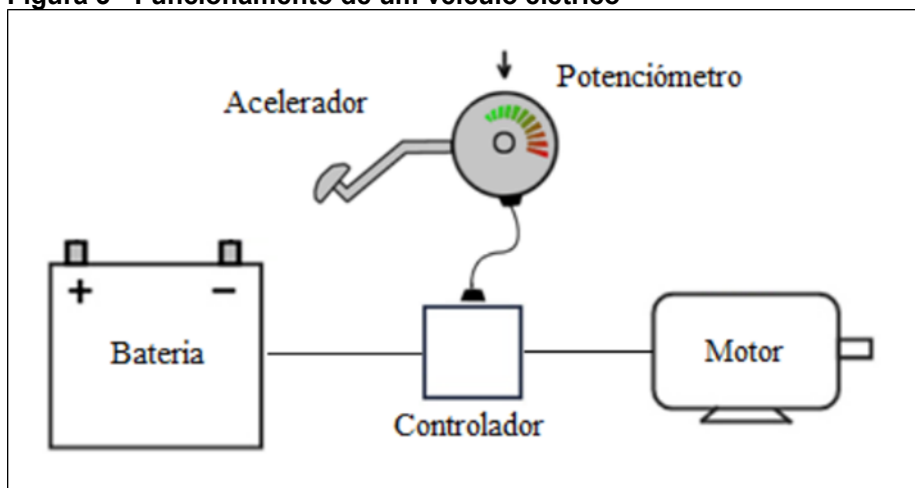
### 2.2.3 Veículos com motor diesel

Além do ciclo de Otto, há também motores que funcionam ao ciclo Diesel, que trabalham de forma diferente em algumas etapas e utiliza o gasóleo (diesel) como combustível. O primeiro tempo (admissão) se difere, pois o combustível é admitido através de uma injeção no máximo da compressão. A combustão se inicia sem ignição elétrica, através de uma autoignição, devido ao oxigênio em alta concentração presente na câmara de combustão. Esse ciclo pode funcionar com dois ou quatro tempos (LIMA et al, 2019).

A queima do diesel, que tem maior ponto de ebulição comparado com a gasolina, faz com que o cilindro ainda seja carregado por combustível na fase líquida durante a combustão, o que gera um processo que dá origem ao MP carbonoso. A elevada temperatura na câmara também possibilita a formação de  $\text{NO}_x$ , que reage com  $\text{O}_2$  e  $\text{N}_2$  do ar (DRUMM et al, 2014). Segundo uma pesquisa de HE et al (2003), que mistura etanol com diesel em um motor operado por Ciclo Diesel, com maiores quantidades de diesel, as emissões são maiores, pois se adicionada uma maior parcela de etanol, as emissões de  $\text{NO}_x$ , CO e  $\text{CO}_2$  diminuem.

### 2.2.4 Veículos elétricos

Os veículos elétricos podem funcionar através de baterias e motores. Os principais motores usados são de Corrente Contínua (CC), de indução, de relutância comutado (SEM) e motor síncrono de ímãs permanentes (PMS ou BLAC). Para os motores, há um aparelho que controla alguns parâmetros nele como velocidade, aceleração e travagem regenerativa. A Figura 3 esquematiza o funcionamento de um tipo de veículo elétrico (FREITAS, 2012).

**Figura 3 - Funcionamento de um veículo elétrico**

Fonte: Freitas, 2012.

Para o funcionamento dos veículos elétricos é necessário ter um armazenamento de energia, esse podendo ser em baterias do tipo: recarregáveis; em ultracondensadores, células de combustível (*fuel cell*), entre outras opções que são mais inviáveis. Como as baterias recarregáveis são as mais utilizadas para armazenar energia em veículos elétricos, elas devem ter boa densidade energética e capacidade de descarga, além disso é necessário ter postos de abastecimento para esse tipo de veículo, com possibilidade de recarga em corrente contínua e disponibilidade de cabos conectores para realização da recarga (FREITAS, 2012).

Já que não ocorre a queima de combustível nem a eliminação de gases durante o funcionamento de veículos puramente elétricos, a poluição gerada por eles em movimento é praticamente nula. Portanto, para saber o papel de veículos elétricos nas emissões atmosféricas, deve-se levar em conta como a energia elétrica utilizada por eles é gerada, e se aprofundar mais o estudo, realizar uma avaliação do ciclo de vida dos veículos (SOUZA et al, 2016).

Segundo Noce (2009), para que o país tenha uma frota de veículos elétricos, é importante que tenha uma viabilidade energética para que a frota seja adequada à oferta de energia e não tenha sobrecarga no sistema elétrico nacional. Utilizando de métodos de previsão, Dias et al (2014) realizaram uma pesquisa no estado de São Paulo, o principal no Brasil em termos econômicos, com o intuito de verificar os impactos causados pela inserção de veículos elétricos na demanda de eletricidade e nas emissões atmosféricas. Como resultado observado no cenário base estudado,

tem-se que com o aumento de 10% da frota de carros elétricos, aumenta-se 2% da demanda de energia elétrica no estado e reduz-se em 1,3% o total de emissões.

Já os estudos de Baran e Legey (2013), que analisam os impactos do aumento de veículos elétricos no consumo de energia elétrica nível Brasil, também utilizando de métodos de previsão, concluem que o uso de energia não necessariamente atuaria como substituto, mas como complemento para a gasolina e etanol. A produção de energia no país, que em sua maioria é de fontes renováveis, é um fator que torna a alternativa mais atrativa. A vantagem de se usar energias advindas de fontes renováveis ao invés de gasolina, é que elas dependem menos de matéria-prima estrangeira e não estão sujeitas às oscilações de preço do mercado de petróleo.

#### 2.2.5 Veículos híbridos

Veículos híbridos são veículos que combinam o uso de motores a combustão interna com motores elétricos, portanto também são uma alternativa que realiza uma menor queima de gases. O motor da combustão pode ser usado para carregar as baterias ou tracionar o veículo, mas há um modelo de híbrido chamado de *plug-in* que pode ter sua bateria recarregada se ligado à rede elétrica (VONBUN, 2015).

Segundo Souza et al (2016), uma das vantagens dos veículos híbridos é sua flexibilidade de operação, que se configurado de forma adequada, trabalha com um mínimo de consumo de combustível e de emissões. Como as concessionárias de energia elétrica trabalham em nível de subutilização em grande parte do tempo, quando não há períodos de pico o sistema consegue gerar e fornecer a energia necessária para abastecimento dos veículos em quantidade substancial, com baixo custo marginal e menos emissões que veículos que funcionam somente à combustão.

### 2.3 PROJETO ROTA 2030

Na última década, dois programas de incentivo ao desenvolvimento da indústria automobilística foram desenvolvidos no Brasil. O primeiro, que entrou em vigor em 2013 e foi válido até 2017, é o Inovar-Auto, que objetivou uma maior

competitividade no mercado automotivo. Para isso, suas metas consistiam em capacitar os fornecedores, ter investimentos mínimos no Pesquisa e Desenvolvimento (P&D) e produzir veículos mais seguros e econômicos (FONSECA, 2018).

Como substituto do Inovar-Auto, o Rota 2030 é um programa remodelado lançado em 2018 com a Lei 13.755, de 10 de dezembro de 2018. A linha estratégica deste programa é similar à de seu antecessor, porém o novo foco principal de seus objetivos é o incentivo a projetos de P&D na cadeia completa do setor automotivo. Enquanto o Inovar-Auto era limitado a montadoras, o Rota 2030 então se amplia a setores de autopeças e a sistemas estratégicos da produção de veículos.

Os beneficiados pelo regime tributário que foi instituído no art. 20 da Lei 13.755 são: “empresas que atendam aos termos, aos limites e às condições estabelecidos pelo Poder Executivo federal.” Sendo elas “empresas habilitadas que importem autopeças destinadas à industrialização dos produtos automotivos a que se refere o art. 22 desta Lei”. Os produtos automotivos considerados no art. 22 são automóveis e veículos comerciais leves; ônibus; caminhões; tratores rodoviários para semirreboques; chassis com motor; reboques e semirreboques; carrocerias e cabinas; tratores agrícolas, colheitadeiras e máquinas agrícolas autopropulsadas; máquinas agrícolas autopropulsadas; máquinas rodoviárias autopropulsadas; e autopeças.

Conforme a Lei 13.755, em relação as montadoras dos veículos, haverá uma redução do Imposto sobre Produtos Industrializados (IPI) para veículos híbridos que contém motor que utiliza gasolina e álcool em relação aos veículos convencionais (mínimo 3%), veículos que atenderem a requisitos específicos de eficiência energética (até 2%) e para os veículos que atenderem a requisitos específicos de desempenho estrutural associado a tecnologias assistivas à direção (até 1%).

Entre os principais incentivos fiscais que a Lei 13.755 proporciona, está a dedução da Contribuição Social sobre o Lucro Líquido (CSLL) e do Imposto sobre a Renda das Pessoas Jurídicas (IRPJ) para as empresas fornecedoras de peças, “devidos o valor correspondente à aplicação da alíquota e adicional do IRPJ e da alíquota da CSLL sobre até 30% (trinta por cento) dos dispêndios realizados no País, no próprio período de apuração, desde que sejam classificáveis como despesas operacionais pela legislação do IRPJ”. De acordo com o art. 11 desta lei, esse valor deve ser destinado a aplicações de pesquisa e desenvolvimento.

Também da mesma seção é definido que caso haja dispêndios com pesquisa e desenvolvimento tecnológico que sejam considerados estratégicos, “a empresa

poderá beneficiar-se de dedução adicional do IRPJ e da CSLL correspondente à aplicação da alíquota e adicional do IRPJ e da alíquota da CSLL sobre até 15% (quinze por cento) incidentes sobre esses dispêndios, limitados a 45% (quarenta e cinco por cento) dos dispêndios de que trata o caput deste artigo” (Lei 13.755, seção IV, art. 11, parágrafo 4).

De acordo com Fonseca (2018), uma das empresas que fará proveito do incentivo é a Toyota, que anunciou um investimento de 1,6 bilhões de reais para aumentar sua capacidade produtiva e produzir o veículo elétrico Toyota Prius em fábricas na cidade de São Paulo. O projeto Rota 2030, segundo Silva e Veloso (2017), contribuirá para o mercado automobilístico com veículos de maior eficiência, segurança e sustentabilidade, já que estes trazem menos emissões de gases poluentes à atmosfera, o que é benéfico ao meio ambiente e a qualidade de vida do homem. Outra consequência esperada pelo projeto é o aumento do consumo de produtos nacionais.

## 2.4 PANDEMIA DO CORONAVÍRUS

Ao final do ano de 2019, iniciou-se na China a epidemia de um vírus que logo atingiu uma escala global. No Brasil, os primeiros casos foram notificados no início de 2020, sendo que no mês de abril, já haviam sido registrados cerca de 1,2 mil mortes causadas pelo vírus e 21 mil casos confirmados de infectados (WERNECK; CARVALHO, 2020).

A COVID-19, que é causada pelo coronavírus (SARS-CoV-2), pode ser transmitida tanto pelo contato físico (a objetos ou pessoas contaminadas) como pelo ar. Com fácil transmissão, logo o vírus se espalhou tornando-se uma pandemia, um acontecimento marcante e destrutivo a vida humana que causou profundos impactos ao redor do mundo (MARTINS et al, 2020).

De acordo com Janus, 2021, esses impactos logo se manifestaram no mercado econômico mundial, principalmente em países emergentes. No Brasil, foram adotadas medidas restritivas de circulação de pessoas e realização de atividades. Com isso, a população brasileira lida com uma situação de vulnerabilidade e altas

taxas de desemprego, o que reflete os danos econômicos causados pela pandemia (WERNECK, CARVALHO).

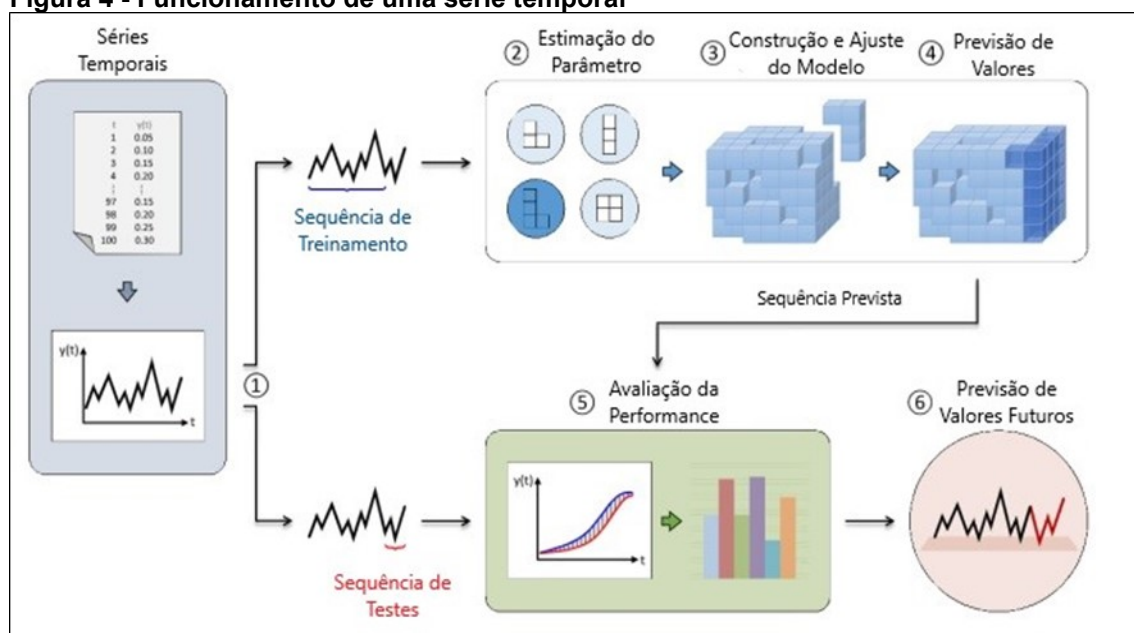
## 2.5 ESTUDO DE PREVISÕES A PARTIR DE SÉRIES TEMPORAIS

Para que seja possível analisar o comportamento da quantidade de veículos elétricos licenciados no Brasil em relação ao licenciamento de outros veículos, a produção de combustível e a emissão de CO<sub>2</sub> no país, é necessária a aplicação de um estudo preditivo de séries temporais, através de metodologias paramétricas e não paramétricas.

### 2.5.1 Séries temporais

Uma análise de séries temporais é o estudo de uma série de dados que se encontram em um intervalo de tempo fixo, com o objetivo de encontrar características que definem um padrão de toda a estrutura, para que assim seja possível realizar a previsão de dados futuros (SUHERMI et al, 2018).

**Figura 4 - Funcionamento de uma série temporal**



Fonte: Adaptação de Parmezan, Souza e Batista (2019).

De acordo com Parmezan, Souza e Batista (2019), o estudo de previsão de dados a partir de séries temporais pode ser dividido em duas principais vertentes: treinamento e teste:

- Etapa de Treinamento: Como pode ser observado na Figura 4, a etapa de treinamento é responsável pela definição dos parâmetros e o modelamento da rede, para que assim seja possível realizar o treinamento em função dos valores já conhecidos da rede. A definição da estrutura é realizada com base no tipo de metodologia de previsão escolhida (ARIMA, Redes Neurais Artificiais, etc.) para a definição dos parâmetros, dos quais a função é minimizar ao máximo os erros de previsão. Após a definição dos parâmetros, é necessário construir o modelo da série temporal, que será utilizado na etapa final do treinamento para prever os valores da variável dependente já conhecidos.

- Etapa de Teste: A etapa de testes se inicia em função dos valores previstos durante a etapa de treinamento, os quais são comparados com os valores reais da base de dados a fim de encontrar o erro de previsão, realizando uma performance da estrutura e fazendo uma melhoria nos parâmetros se necessário, como pode ser observado na Figura 4. Depois que a rede já foi otimizada e os parâmetros foram definidos a fim de se produzir o menor erro de previsão possível, finalmente é realizada a previsão dos valores futuros da variável dependente. Para manter um grau maior de confiabilidade na série temporal, é recomendado sempre comparar os valores previstos com os valores futuros assim que estiverem disponíveis, alterando o modelo ou reajustando os parâmetros quando necessário.

## 2.6 ANÁLISE ESTATÍSTICA

O desempenho das previsões realizadas no trabalho é avaliado por meio de uma análise estatística. Essa análise é feita utilizando os métodos e conceitos estatísticos.

### 2.6.1 Regressão Linear

O modelo de Regressão Linear utiliza de um conjunto de técnicas estatísticas para modelar as relações entre variáveis dependentes e independentes. Seu objetivo é prever o valor de uma variável dependente através de uma (modelo Simples) ou mais (Regressão Linear Múltipla) variáveis independentes (RODRIGUES, 2012).

Para isso, realiza-se a análise de correlação entre essas variáveis, com o coeficiente de correlação linear de Pearson, que determina a “força” do relacionamento entre elas. O coeficiente é dado pela Equação (1), levando em consideração a Equação (2).

$$R_{xy} = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad [1]$$

$$\bar{x} = \sum_{i=1}^n \frac{x_i}{n} \quad e \quad \bar{y} = \sum_{i=1}^n \frac{y_i}{n} \quad [2]$$

Sendo que  $x$  e  $y$  são as variáveis em que será analisada a correlação.

### 2.6.2 Equação da Reta

A equação de uma reta é o que descreve matematicamente o relacionamento entre a variável dependente e as variáveis independentes. Através dela, é possível estimar o valor da variável dependente que está em função das independentes (RODRIGUES; MEDEIROS; GOMES, 2013).

Em um modelo de Regressão Linear Múltipla, a equação da reta é representada pela Equação (3).

$$Y_i = \beta_0 + \beta_1 X_{i1} + \beta_2 X_{i2} + \dots + \beta_p X_{ip} + u_p \quad [3]$$

Sendo que  $Y$  é o valor da variável dependente,  $X$  representa os coeficientes de regressão, em que  $i$  um valor inteiro indo de 1 a  $p$ , onde  $p$  é o número de variáveis



explicativas. O  $u$  é uma constante que corresponde ao erro aleatório (HOFFMANN, 2016).

### 2.6.3 Sazonalidade

A sazonalidade é uma característica de séries temporais que repetem um tipo de comportamento a cada determinado período de tempo. Em uma série temporal mensal sobre a quantidade de brinquedos vendidos em uma loja, por exemplo, pode-se esperar que haja um aumento nas vendas em datas comemorativas, tendo picos nos meses de outubro e dezembro (EHLERS, 2003).

### 2.6.4 Tipos de Erro

A fim de analisar o desempenho dos métodos de previsão testados, aplicam-se testes estatísticos para determinar o erro da previsão. No presente trabalho serão utilizados dois testes apresentados a seguir.

#### 2.6.4.1 Raiz do Erro Quadrático Médio (RMSE)

A Raiz do Erro Quadrático Médio (RMSE) considera que os erros da previsão são imparciais e seguem um tipo de previsão normal (MEDEIROS; ANDRADE; LINS, 2020). Ela pode ser calculada através da Equação (4).

$$RMSE = \left[ \frac{1}{n} \sum_{i=1}^n (y_i - x_i)^2 \right]^{\frac{1}{2}} \quad [4]$$

Nesta equação,  $y_i$  representa a frequência relativa das observações,  $x_i$  a frequência obtida através do método usado e  $n$  é o número das observações.

#### 2.6.4.2 Erro Médio Absoluto (MAE)

O Erro Médio Absoluto (MAE) é usado para calcular a magnitude média dos erros existentes entre os dados da previsão. Nele é considerado que os erros possuem todos o mesmo peso, portanto não se aplicam pesos aos erros para seu cálculo, o que pode significar que este teste apresenta maior imparcialidade que a RMSE, que tem seu resultado final influenciado por erros de valores maiores. Por este motivo, o valor do MAE será sempre menor ou igual ao valor da RMSE (MEDEIROS; ANDRADE; LINS, 2020).

O MAE é calculado pela Equação (5).

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - x_i| \quad [5]$$

Assim como no cálculo da RSME,  $y_i$  representa a frequência relativa das observações,  $x_i$  a frequência obtida através do método usado e  $n$  é o número das observações.

#### 2.6.4.3 Critério de Informação de Akaike (AIC)

O Critério de Informação de Akaike (AIC) é uma métrica utilizada para comparar diferentes modelos estatísticos a fim de selecionar qual apresenta melhor resultado. Ele simula a quantidade de informações perdidas na execução de um modelo, para então selecionar o modelo que melhor equilibra essas “perdas” (GKIOULEKAS; PAPAGEORGIU, 2018).

O cálculo da “pontuação” AIC para seleção do melhor modelo é realizado através da Equação (6).

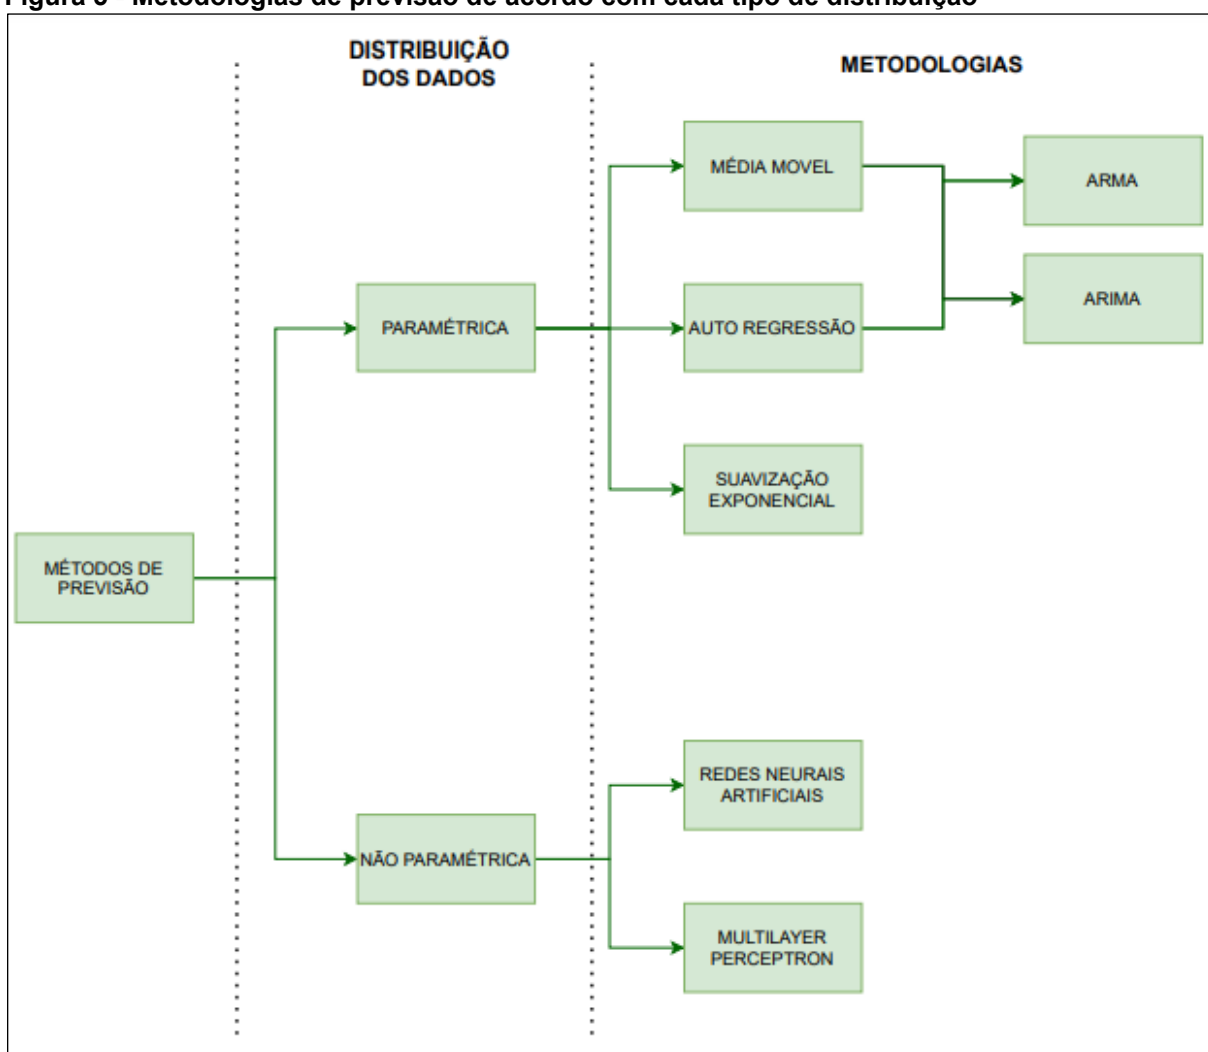
$$AIC = n \cdot \ln\left(\frac{RSS}{n}\right) + 2K \quad [6]$$

Onde  $n$  é o número de observações,  $RSS$  é a soma residual dos quadrados e  $K$  é o número de parâmetros estimados.

## 2.7 MÉTODOS DE PREVISÃO

A escolha do método ideal de previsão varia conforme a distribuição inicial dos dados de determinada série histórica, sendo divididos em distribuições paramétricas e distribuições não paramétricas, distribuições as quais apresentam metodologias específicas, como pode ser observado na Figura 5 (PARMEZAN; SOUZA; BATISTA, 2019).

**Figura 5 - Metodologias de previsão de acordo com cada tipo de distribuição**



Fonte: Autoria própria, 2021.

As metodologias englobadas na Distribuição de Dados Paramétrica são: Média Móvel (MA), Suavização Exponencial (SE), Auto Regressão (AR), Auto Regressivo de Médias Móveis (ARMA), Auto Regressivo Integrado de Médias Móveis (ARIMA) e Heteroscedasticidade Condicional Auto Regressiva (ARCH). Já as metodologias

consideradas na Distribuição de Dados Não Paramétrica são: Redes Neurais Artificiais e Redes *Multilayer Perceptron* (MLP).

### 2.7.1 Métodos paramétricos

Métodos paramétricos são aqueles utilizados para a construção de modelos de previsão e dependem de um conjunto de parâmetros para caracterizar uma distribuição de dados, otimizando os valores de saída da previsão. Esses métodos podem ser divididos em dois diferentes grupos de acordo com suas características matemáticas: modelos de suavização exponencial e modelos ARIMA (MONTGOMERY; JENNINGS; KULAHCI, 2015).

#### 2.7.1.1 Modelo de Média Móvel

O modelo de Média Móvel (MA) é um método usual que busca prever os próximos valores de uma série temporal com base na média aritmética dos últimos  $r$  valores dessa série, explorando a autocorrelação das variáveis através da utilização de um número constante de observações (LUCAS; SACCUCCI, 1990).

A equação que define o modelo de médias móveis pode ser descrita pela Equação (7).

$$Z_{t+1} = \frac{Z_t + Z_{t-1} + Z_{t-2} + \dots + Z_{t-r+1}}{r} \quad [7]$$

Onde  $r$  é o número total de observações e  $Z_t$  é o valor da média no tempo  $t$ .

O número de observações ( $r$ ) implica diretamente na uniformidade dos dados previstos, portanto, quanto maior o  $r$ , maior será o grau de suavização da série temporal. Contudo, um elevado valor de  $r$  impede que a estrutura reaja rapidamente a uma mudança de dados, sendo assim recomendável utilizar um número menor de  $r$  para séries temporais com baixo nível de aleatoriedade (TANG et al, 2019).

### 2.7.1.2 Modelo de Suavização Exponencial

Os modelos de Suavização Exponencial (SE) utilizam o sistema de pesos para trabalhar com as variáveis das séries temporais, sendo esses pesos atribuídos a cada variável e aumentam exponencialmente conforme os intervalos de tempo passam, ou seja, as últimas previsões exercem uma maior influência em relação aos valores que serão previstos futuramente (SYNTETOS; BABAI; GARDNER, 2015).

Conforme Mills (2019), após a definição de todos os pesos, é realizada a interação entre os dados para se obter os valores de previsão, essa interação pode ser representada de forma resumida a partir da Equação (8).

$$Z_t = \alpha x_t + (1 - \alpha)Z_{t-1} \quad [8]$$

Onde  $Z_t$  representa o nível da observação suavizada, o  $\alpha$  ( $0 < \alpha < 1$ ) representa o peso e  $x_t$  equivale ao último valor observado.

### 2.7.1.3 Modelo de Auto Regressão

O modelo Auto Regressão (AR) é amplamente conhecido e usado para diversos campos de pesquisa que trabalham com previsões estatísticas (MOON et al, 2020). De acordo com Parmezan, Souza e Batista (2019), este modelo é responsável por estabelecer o grau de correlação que cada variável tem, ou seja, o quanto uma variável  $x$  vai influenciar uma variável  $y$ . Ele segue a fórmula apresentada na Equação (9).

$$y(n) = \sum_{i=1}^p \varphi(i)y(n-i) + e(n) \quad [9]$$

Na equação,  $y(n)$  é a saída da série temporal e  $\varphi(i)$  é o coeficiente de AR.

#### 2.7.1.4 Modelo ARMA

O modelo Autorregressivo de Médias Móveis (ARMA) é representado pela junção do modelo AR com o modelo MA. A MA é utilizada para ajudar a compreender a interação entre valores que antes eram incompreendidas, possibilitando que esse método também trabalhe com variações de dados sazonais (PARMEZAN; SOUZA; BATISTA, 2019).

De acordo com Yang, Ce e Lian (2016), o ARMA é um modelo de séries temporais aleatório muito usado na análise de séries temporais estatísticas e lineares devido a sua alta performance nos resultados (YANG et al, 2016). Sua fórmula está representada na Equação (10).

$$y(n) = \sum_{i=1}^p \varphi(i)y(n-i) + \sum_{j=0}^q \theta(j)x(n-j) + e(n) \quad [10]$$

Neste caso, o  $y(n)$  é a saída da série temporal que soma o modelo de AR (em ordem de  $p$ ) com o de MA (em ordem de  $q$ ).  $\theta(j)$  representa o coeficiente do modelo MA.

#### 2.7.1.5 Modelo ARIMA

Os modelos ARIMA são utilizados em modelos lineares e operam com três diferentes áreas da estatística, sendo elas: a Auto Regressão (AR), a Integração (I) e a Média Móvel (MA) (SUHERMI et al, 2018).

Complementando os modelos AR e MA já descritos, no ARIMA o “I” é responsável por garantir com que a série temporal se desenvolva ao redor de uma média constante ao passar do tempo, mantendo-se estacionária (PARMEZAN; SOUZA; BATISTA, 2019).

De acordo com Suhermi et al (2018), o modelo geral do método ARIMA pode ser representado pela Equação (11).

$$(1 - B)^d Y_t = \mu + \frac{\theta_q(B)}{\varphi_p(B)} a_t \quad [11]$$

Onde:

$$\phi_p(B) = 1 - \phi_1 B - \phi_2 B^2 - \dots - \phi_p B^p \quad [12]$$

$$\theta_q(B) = 1 - \theta_1 B - \theta_2 B^2 - \dots - \theta_q B^q \quad [13]$$

$$BY_t = Y_{t-1} \quad [14]$$

Sendo,  $Y_t$  os valores reais,  $B$  o operador de defasagem,  $a_t$  os termos de erro,  $\mu$  os parâmetros e  $d$  a ordem de diferenciação.

#### 2.7.1.6 Modelo ARCH

O modelo de Heteroscedasticidade Condicional Auto Regressiva (ARCH) é um modelo usado para captar oscilações na volatilidade de séries temporais (SILVA, SÁFADI, JÚNIOR, 2005). O cálculo de um modelo tipo ARCH(p) é realizado através das equações 15 e 16, em que representa a ordem do modelo,  $\varepsilon_t$  são os erros (não correlacionados serialmente e não independentes estocasticamente), e  $\sigma_t^2$  é a variância condicional do conjunto de informações ( $\Omega_{t-1}$ ) no tempo t-1.

$$\varepsilon_t | \Omega_{t-1} \sim N(0, \sigma_t^2) \quad [15]$$

$$\sigma_t^2 = E[\varepsilon_t^2 | \Omega_{t-1}] = \alpha_0 + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 \quad [16]$$

As restrições do parâmetro que garantem que a variância condicional apresente um valor positivo e seja fracamente estacionária são:  $\alpha_0 > 0$ ,  $\alpha_i > 0$  para todo  $i = 2 \dots p$  e  $\sum \alpha_i < 1$ .

#### 2.7.2 Métodos não paramétricos

Diferente dos métodos de previsão paramétricos, os não paramétricos não necessitam de um conhecimento antecipado da distribuição da série temporal, não

dependendo assim de parâmetros para elaboração da estrutura da série. Esse tipo de método possibilita o trabalho com séries com um maior nível de complexidade e séries que apresentam uma distribuição não-linear de seus dados, apresentando fácil manutenção e com resultados confiáveis (ISLAM; SIVAKUMAR, 2002).

#### 2.7.2.1 Redes Neurais Artificiais


Redes Neurais Artificiais (RNA) recebem este nome por apresentarem uma estrutura computadorizada semelhante ao sistema nervoso humano, sendo definidas como uma rede de processamento massivo paralelo. As RNA trabalham com variáveis não-lineares e cada estrutura de sua rede apresenta capacidade de armazenamento de informação, possibilitando uma aplicação futura (HAYKIN, 2008).

Uma RNA é fundamentada em uma simples função  $F: X \rightarrow Y$ , sendo X as variáveis não-lineares de entrada (*input*) e Y as de saída (*output*), tornando-se assim possível estabelecer uma relação entre estas variáveis (GAO; YIN; NING, 2018).

A confiabilidade dos dados de uma Rede Neural Artificial é possibilitada graças a sua estrutura formada por pelo menos três camadas de dados, sendo uma camada de entrada (*input layer*), que possui uma maior quantidade de dados, a camada de saída (*output layer*), que apresenta os resultados de previsão da variável dependente e as camadas ocultas (*hidden layer*), que são responsáveis pelo estudo e armazenamento das características dos dados, como pode ser observado na Figura 6 (GAO; YIN; NING, 2018).



**Figura 6 - Estrutura de uma Rede Neural Artificial**



Fonte: Autoria própria, 2019.

Uma Rede Neural Artificial pode apresentar duas maneiras distintas de ligação entre suas variáveis, sendo elas: recorrentes e não recorrentes. As ligações recorrentes ou cíclicas, são caracterizadas pelas variáveis percorrerem a mesma rota mais de uma vez, enquanto as não recorrentes ou de Alimentação Adiante (*Feedforward*) seguem sempre em frente, sendo caracterizadas como acíclicas (ROITMAN, 2001).

#### 2.7.2.2 Redes *Multilayer Perceptron* (MLP)

*Multilayer Perceptron* (MLP) é uma metodologia utilizada na área de Redes Neurais Artificiais que usa uma arquitetura de dados *FeedForward*, sendo a metodologia mais reconhecida e utilizada atualmente. A popularidade das redes MLP está ligada à sua capacidade de lidar com dados não-lineares, envolvendo problemas como catalogações de padrões, aproximação de funções e previsão de séries temporais (LIMA-JUNIOR; CARPINETTI, 2019).

O funcionamento das redes MLP se baseia na utilização de algoritmos de aprendizado supervisionado, sendo o mais conhecido dentre eles o algoritmo de Retroprogramação. A utilização de algoritmos nas séries históricas permite com que a rede MLP se adeque facilmente a qualquer ambiente escolhido para o trabalho (ROITMAN, 2001).

Segundo Lima-Junior e Carpinetti (2019), o desenvolvimento do algoritmo de retroprogramação é dividido em duas etapas: *forward* (para frente) e *backward* (para trás). Durante a etapa *forward*, são usados os valores de  $x_{ij}$  e os  $w_{ij}$ , que são escolhidos de forma empírica, para se obter o valor de  $Y_j^{(2)}$ , que é calculado com base nas equações [17]-[21]. Em seguida, a etapa *backward* utiliza as equações [22]-[25] para ajustar os valores dos pesos  $w_{ij}$  e do  $\theta$ , a fim de diminuir ao máximo o erro quadrático médio entre os valores originais e os previstos durante o período de treinamento. O processo de retroprogramação é repetido até que os valores dos pesos gerem um erro quadrático mínimo, obtendo-se assim uma maior confiabilidade nos valores previstos.

$$y = g(\sum_{i=0}^n w_i \cdot x_i - \theta) \quad [17]$$

$$I_j^{(1)} = \sum_{i=0}^n W_{ji}^{(1)} x_i \quad [18]$$

$$Y_j^{(1)} = g(I_j^{(1)}) \quad [19]$$

$$I_j^{(2)} = \sum_{i=0}^n W_{ji}^{(2)} Y_i^{(1)} \quad [20]$$

$$Y_j^{(2)} = g(I_j^{(2)}) \quad [21]$$

Sendo:  $g$  a função de ativação,  $Y_j^{(1)}$  os valores de saída dos neurônios da camada oculta,  $Y_j^{(2)}$  os valores finais da camada de saída,  $I_j^{(1)}$  os valores de entrada na camada oculta,  $I_j^{(2)}$  os valores de entrada na camada de saída,  $\theta$  o limite de ativação,  $w_{ij}$  os pesos sinápticos e  $x_{ij}$  os valores de entrada.

$$W_{ji}^{(2)}(t+1) = W_{ji}^{(2)}(t) + n \cdot \delta_j^{(2)} \cdot Y_i^{(1)} \quad [22]$$

$$\delta_j^{(2)} = (d_j - Y_j^{(2)}) \cdot g'(I_j^{(2)}) \quad [23]$$

$$W_{ji}^{(1)}(t+1) = W_{ji}^{(1)}(t) + n \cdot \delta_j^{(1)} \cdot x_i \quad [24]$$

$$\delta_j^{(1)} = \left( \sum_{i=0}^n \delta_k^{(2)} \cdot W_{ji}^{(2)} \right) \cdot g(I_j^{(1)}) \quad [25]$$

Sendo:  $(t)$  referente os valores anteriores,  $n$  a taxa de aprendizado,  $\delta_j^{(2)}$  os valores gradientes locais de saída e  $d_j$  são os valores esperados.

### 3 METODOLOGIA

Neste capítulo, dividido em três seções, são apresentadas as etapas de desenvolvimento do trabalho e a metodologia utilizada. A primeira seção é sobre a classificação da pesquisa de acordo com a literatura, a segunda explica todas suas etapas de desenvolvimento, e a última contém o cronograma das atividades.

#### 3.1 CLASSIFICAÇÃO DA PESQUISA

A pesquisa busca testar métodos de previsão quantitativos através de séries temporais para determinar dados futuros do licenciamento de veículos elétricos no Brasil. Sabendo suas características, é possível classificá-la de acordo com sua finalidade, abordagem, objetivos e procedimentos utilizados conforme a literatura.

##### 3.1.1 Natureza da pesquisa

A pesquisa trata-se de uma aplicação prática de metodologias já existentes, proporcionando uma maior compreensão sobre determinado tema. Portanto, segundo Gil (2008), ela é de natureza aplicada, pois tem um desenvolvimento científico que traz consequências práticas ao conhecimento teórico em uma realidade circunstancial, diferente da pesquisa pura, que busca um desenvolvimento formalizado e construção de teorias.

##### 3.1.2 Abordagem

O estudo tem uma abordagem quantitativa, pois é apto a mensurar suas variáveis em escalas numéricas através de ferramentas estatísticas, podendo então quantificar as variáveis em sua coleta e tratamento. Esse tipo de pesquisa geralmente contém tabelas e gráficos para representação dos dados (BRUCHÊZ et al, 2015).

### 3.1.3 Objetivos

O objetivo do presente trabalho é definido como exploratório, pois trata-se de um estudo em uma área não muito explorada, buscando proporcionar uma visão mais precisa sobre o tema escolhido tendo como base um levantamento bibliográfico, auxiliando assim possíveis estudos posteriores nesta mesma área (GIL, 2008).

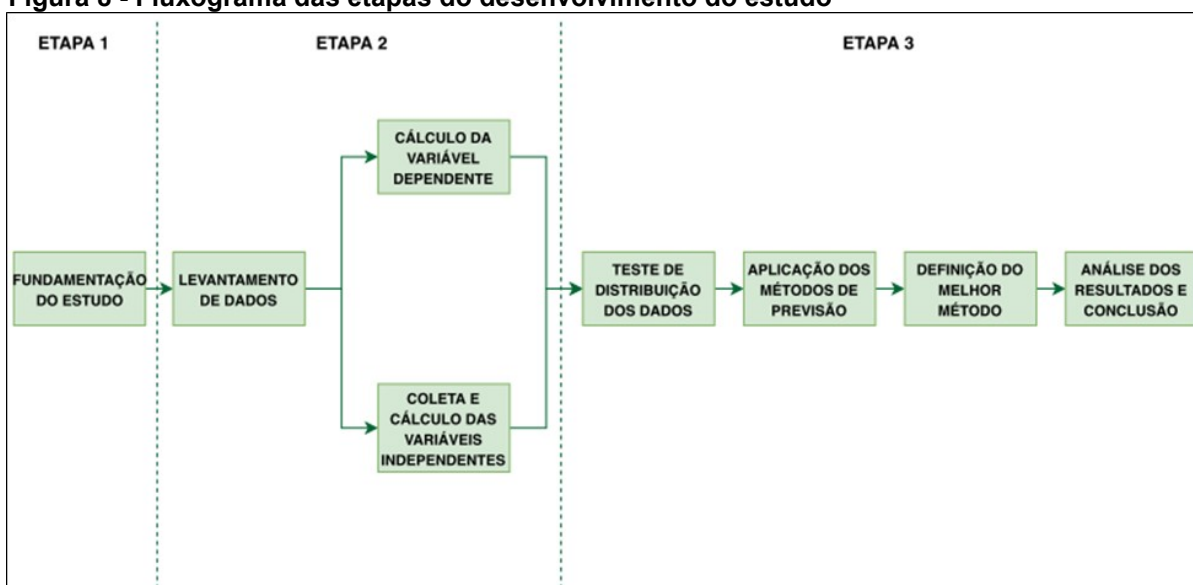
### 3.1.4 Procedimentos

Quanto aos procedimentos utilizados, a metodologia da pesquisa é classificada como modelagem e simulação. Ela usa técnicas analíticas para detalhar o funcionamento de um sistema (modelagem), e com isso simula tal funcionamento através de técnicas computacionais (simulação), fazendo então um desenvolvimento, análise e teste das variáveis (MIGUEL et al, 2010).

## 3.2 ETAPAS DO DESENVOLVIMENTO

O desenvolvimento do trabalho é dividido em três etapas, que são explicadas nas próximas subseções e estão representadas na Figura 8.

**Figura 8 - Fluxograma das etapas do desenvolvimento do estudo**



Fonte: Autoria própria, 2019.

A primeira etapa consiste na pesquisa para fundamentação do estudo a ser realizado, a segunda é o levantamento dos dados obtidos e definição das variáveis, e a última trabalha com a aplicação dos métodos para a escolha de qual o melhor a ser utilizado.

### 3.2.1 Fundamentação do estudo

O primeiro passo para desenvolvimento do trabalho foi realizar uma pesquisa bibliográfica relacionada ao tema de estudo proposto, a fim de fundamentar todos os tópicos presentes no trabalho com base em artigos científicos de revistas, periódicos e congressos, e análises de livros, dissertações e teses presentes na literatura.

Os materiais de apoio foram obtidos por meio das seguintes plataformas: Science Direct, Portal de Periódicos da Capes, Google Acadêmico e Portal oficial da Presidência da República do Brasil (Lei nº 13.755, de 10 de dezembro de 2018).

### 3.2.2 Levantamento de dados

Para o estudo de previsão com base em séries temporais, os dados encontrados estão divididos em um intervalo de tempo mensal, iniciando em janeiro de 2012 e finalizando em dezembro de 2025, totalizando 168 dados para cada variável independente, sendo o período de 2012 até janeiro de 2021 para os dados reais coletados e de fevereiro de 2021 até dezembro de 2025 para os dados previstos.

Para o desenvolvimento de tal estudo, primeiro é necessário fazer o levantamento da variável dependente (licenciamento de veículos elétricos) e de todas as variáveis independentes que estão relacionadas com a dependente. O conjunto de todos os dados levantados para o trabalho encontra-se no Anexo 1.

As variáveis independentes (X) foram definidas levando em consideração a relação direta de cada uma delas com a variável dependente (Y), sendo essas variáveis: veículos licenciados no país baseando-se no tipo de motor (gasolina, *flex fuel*, diesel), quantidade de combustível produzido no Brasil (gasolina, diesel, etanol hidratado e etanol anidro), e emissão veicular de CO<sub>2</sub>.

### 3.2.2.1 Licenciamento de veículos elétricos

A variável dependente (Y) escolhida para realização do trabalho é o número de veículos elétricos licenciados no Brasil.

Os dados foram extraídos a partir da base de dados estatísticos disponível no endereço eletrônico da Associação Nacional dos Fabricantes de Veículos Automotores (ANFAVEA), que disponibiliza a quantidade mensal de veículos licenciados a partir de 2012 até o período atual.

### 3.2.2.2 Veículos licenciados com base no tipo de motor

Os veículos licenciados foram divididos com base no tipo de motor de cada veículo, totalizando 3 tipos de variáveis nessa área, sendo elas: licenciamento de veículos com motor a gasolina, motor *flex* (álcool e gasolina) e motor a diesel.

Assim como os dados do licenciamento de veículos elétricos, os das demais categorias de veículos também foram obtidos na base de dados estatísticos da ANFAVEA.

### 3.2.2.3 Quantidade de combustível produzido

Nesta área foi coletada a quantidade de produção nacional de todos os tipos de combustíveis sendo eles: gasolina, diesel, etanol hidratado e etanol anidro.

Os dados foram coletados a partir da base de dados estatísticos disponível no endereço eletrônico da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), que disponibiliza a quantidade mensal produzida de cada variável a partir de 2012 até o período atual.

### 3.2.2.4 Emissão de CO<sub>2</sub>

As quantidades emitidas de CO<sub>2</sub> foram calculadas com base em uma adaptação da metodologia fornecida pela plataforma online do Sistema de Estimativa de Emissão de Gases (SEEG), através da Equação (26).

$$E_{CO_2} = Cons * p_{energia} * Fe_{CO_2} \quad [26]$$

Onde,  $E_{CO_2}$  representa a quantidade emitida de CO<sub>2</sub> (kgCO<sub>2</sub>/mês),  $Cons$  é a quantidade de combustível consumida no intervalo de tempo,  $p$  é a densidade energética do combustível e  $Fe_{CO_2}$  é o fator de emissão (kgCO<sub>2</sub>/TJ).

A variável de densidade energética foi obtida pelo Balanço Energético Nacional (BEN), disponibilizado na plataforma online da Empresa de Pesquisa Energética (EPE), enquanto os fatores de emissão foram obtidos através da plataforma do *Intergovernmental Panel on Climate Change* (IPCC).

**Tabela 1 - Densidade energética de cada tipo de combustível**

Tipo de Combustível	Densidade
Gasolina	0,848
Diesel	0,770
Tipo de Combustível	Densidade
Etanol H	0,510
Etanol A	0,534

Fonte: Empresa de Pesquisa Energética – EPE (2007).

**Tabela 2 – Fatores de emissão de CO<sub>2</sub> por tipo de combustível**

Tipo de Combustível	Fatores de emissão CO <sub>2</sub>
Gasolina	69300
Diesel	74100
Etanol H	70800
Etanol A	70800

Fonte: Intergovernmental Panel on Climate Change, volume 2, capítulo 2 - IPCC (2006).

Para a aplicação do tema escolhido, a fórmula foi adaptada substituindo a variável Quantidade de Combustível Consumido pela Quantidade de Combustível Produzido no Brasil, que corresponde aos dados disponíveis para realização da pesquisa.



### 3.2.3 Escolha do método

Após o levantamento de toda a base de dados, o próximo passo é definir qual dos métodos de previsão será utilizado no estudo. O processo de definição do método será feito através das etapas a seguir.

#### 3.2.3.1 Estudo de correlação

Para definição de como os dados devem ser trabalhados, primeiramente é feito um teste de correlação (realizado com o auxílio do *software* SPSS) que irá identificar qual o grau de correlação entre as variáveis independentes com a variável dependente.

Os índices de correlação podem ser classificados como fraco, moderado e forte, de acordo com o valor de correlação de cada variável, conforme observado na Tabela 3. Além disso, a correlação também pode ser classificada como diretamente proporcional (positiva) ou inversamente proporcional (negativa).

**Tabela 3 – Grau de correlação**

Valor de correlação	Interpretação
0 a 0,39	Fraca
0,40 a 0,69	Moderada
0,70 a 1,00	Forte

**Fonte: Autoria própria.**

#### 3.2.3.2 Previsão das variáveis independentes

Com o estudo de correlação completo, o próximo passo é realizar a previsão das variáveis independentes. A previsão destas variáveis será realizada com o auxílio de *softwares* de previsão (Palisade @RISK e Gretl).

Os métodos utilizados no estudo de previsão das variáveis independentes são: Auto Regressão (AR), Média Móvel (MA), ARMA e ARCH. A escolha do método será por meio das previsões que apresentarem os melhores resultados com base na análise da série histórica como um todo.

### 3.2.3.3 Aplicação do método

Após identificar o tipo de distribuição dos dados, é possível aplicar os métodos anteriormente citados que comportam tal distribuição, obtendo assim os valores previstos do licenciamento de veículos elétricos no intervalo de tempo desejado.

A definição do melhor método será baseada na análise dos resultados apresentados, buscando identificar qual destes apresenta um menor erro quadrático médio em relação aos valores reais e os valores previstos, definindo assim a base de dados completa (com os valores previstos) que será utilizada na análise de resultados e conclusão da pesquisa.

A escolha do erro quadrático médio para à análise dos resultados se explica pelo fato deste método trabalhar considerar o erro sistemático em sua análise, identificando assim o comportamento dos valores previstos como um todo em função dos valores reais (BUSSAB; MORETTIN, 2002).

## 4 RESULTADOS E DISCUSSÃO


Nesta seção serão apresentados os resultados das previsões propostas no trabalho, de acordo com a ordem executada na aplicação das metodologias, sendo primeiramente apresentados os resultados das previsões das variáveis independentes, seguidos pela previsão da dependente (licenciamento de veículos elétricos).

### 4.1 PREVISÃO DAS VARIÁVEIS INDEPENDENTES

As variáveis independentes previstas são: licenciamento de veículos com motor a gasolina, licenciamento de veículos com motor *flex*, licenciamento de veículos com motor a diesel, produção de gasolina, produção de diesel, produção de etanol hidratado, produção de etanol anidro e CO<sub>2</sub> emitido.

Os resultados obtidos para as previsões vão até dezembro de 2025 e serão apresentados em forma de gráfico, sendo representados com base na legenda indicada na Figura 10, onde o verde refere-se aos dados coletados para as variáveis independentes e o azul é referente as previsões.

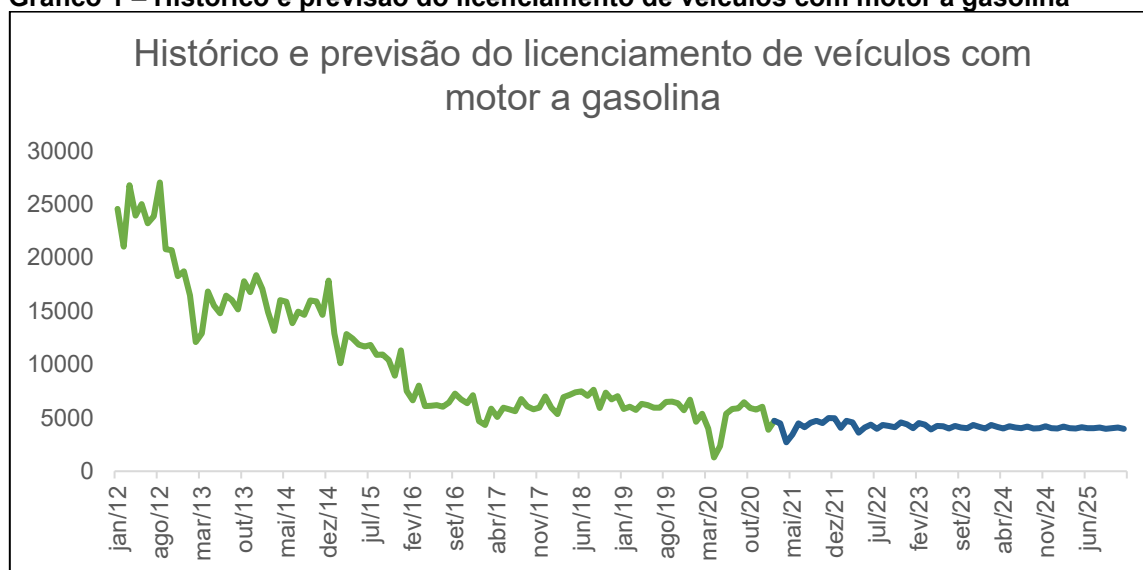
**Figura 10 – Legenda dos gráficos de previsão das variáveis independentes**



**Fonte: Autoria própria, 2021.**

Em todos os gráficos das previsões das variáveis independentes é possível observar uma mudança significativa no comportamento das variáveis no período entre fevereiro e outubro de 2020. Essa mudança de comportamento é justificada pela pandemia do Covid-19 que impactou diretamente na quantidade de veículos licenciados e combustíveis produzidos.


A escolha do *software* e do método previsão utilizado em cada variável independente foi baseada na análise dos erros de previsão e no comportamento da série histórica.

**Gráfico 1 – Histórico e previsão do licenciamento de veículos com motor a gasolina**

Fonte: Autoria própria, 2021.

Ao analisarmos o comportamento da série histórica no Gráfico 1, é possível notar que a variável segue uma tendência negativa, se estabilizando na média de 6000 unidades após o final de 2016.

A previsão da quantidade de licenciamento dos veículos com motor a gasolina foi realizada com auxílio do *software* Gretl, utilizando o método de AR, o qual apresentou os melhores resultados com base nos erros de previsão. Nota-se que os valores previstos seguem com a tendência negativa observada anteriormente, tendo uma baixa variabilidade entre os intervalos previstos.


**Gráfico 2 – Histórico e previsão da quantidade de veículos licenciados com motor flex**

Fonte: Autoria própria, 2021.

A série histórica do licenciamento dos veículos com motor *flex* é representada pelo Gráfico 2 e apresenta uma característica sazonal, tendo uma queda notável nos meses de dezembro e um aumento gradual durante o resto do ano.

Os valores foram previstos pelo método ARMA, utilizando *software* @RISK, o qual obteve o menor percentual de erros de previsão. Pode-se observar que os dados previstos seguem com a característica sazonal da série histórica, seguindo com uma pequena queda com o passar dos anos, ou seja, com uma tendência negativa.


**Gráfico 3 – Histórico e previsão da quantidade de veículos licenciados com motor a diesel**



Fonte: Autoria própria, 2021.

O número de veículos licenciados com motor a diesel é representado por uma série histórica com grande variabilidade durante o passar dos anos, mantendo distribuição com baixa sazonalidade e com tendência positiva, conforme observado no Gráfico 3.


A previsão foi realizada com ajuda do *software* Gretl, utilizando o método de AR. Os valores previstos seguem uma distribuição sazonal visivelmente mais forte do que a presente na série histórica anterior à previsão, tendendo a uma estabilização dos dados com uma característica positiva (aumentando com o passar dos anos).

**Gráfico 4 – Histórico e previsão da produção de gasolina (m³)**

Fonte: Autoria própria, 2021.

A quantidade mensal de gasolina produzida apresenta uma distribuição não-sazonal, com tendência negativa a partir do ano de 2015 e uma grande variação durante os intervalos de tempo.

A previsão da produção da gasolina (m³) foi realizada pelo método AR, com auxílio do *software* Gretl. Ao analisarmos o Gráfico 4, é possível notar que os valores previstos passam a apresentar uma tendência de crescimento (positiva) a partir de abril de 2021, seguindo com aumento constante até o final de 2025.


**Gráfico 5 – Histórico e previsão da produção de diesel (m³)**

Fonte: Autoria própria, 2021.

O histórico de produção de Diesel por m<sup>3</sup> é descrito por uma série com distribuição levemente sazonal, com tendência negativa a partir do final de 2015, recuperando-se apenas no final de 2017.

O método selecionado para a previsão da variável foi o ARCH(1), previsto com auxílio do *software* @RISK. Analisando o Gráfico 5, podemos observar que os dados previstos apresentam uma distribuição sazonal bem definida, com tendência negativa.

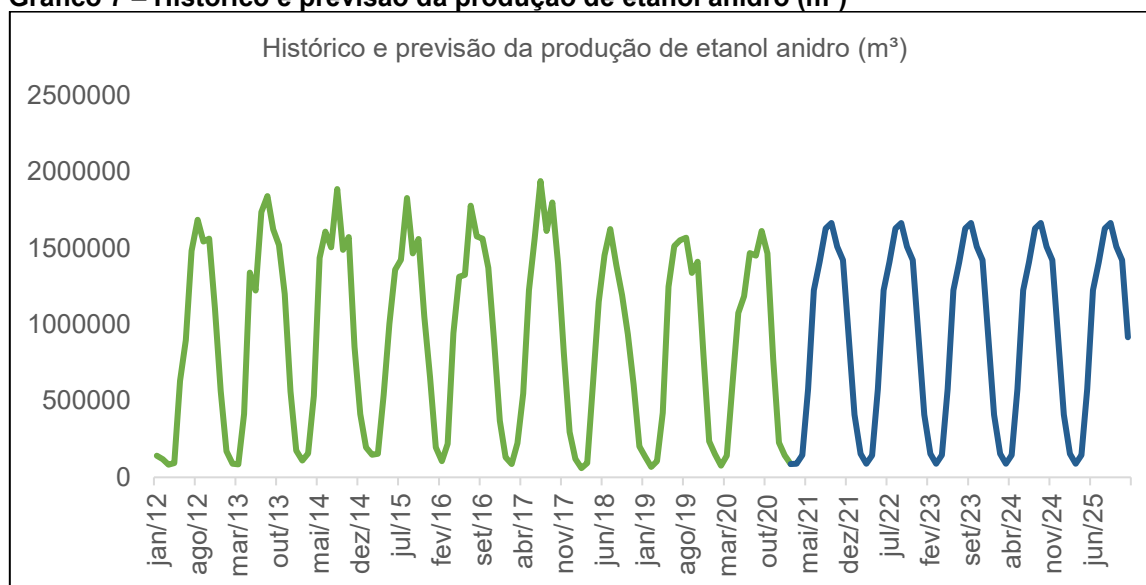
**Gráfico 6 – Histórico e previsão da produção de etanol hidratado (m<sup>3</sup>)**



Fonte: Autoria própria, 2021.

Ao analisarmos o Gráfico 6, é possível notar que a série histórica da produção de etanol hidratado apresenta uma tendência positiva, com um aumento gradual ao passar dos anos e uma distribuição sazonal, com aumento entre os meses de janeiro a agosto e queda entre os meses de setembro a dezembro de cada ano.


Com auxílio do *software* @RISK, o método que apresentou melhores resultados de previsão foi o AR(1). Os valores previstos seguem a mesma sazonalidade da série histórica, sendo possível observar um aumento constante com o passar dos anos.

**Gráfico 7 – Histórico e previsão da produção de etanol anidro (m<sup>3</sup>)**

Fonte: Autoria própria, 2021.

A produção do Etanol Anidro por m<sup>3</sup> também é representada por uma distribuição sazonal dos dados, semelhante ao Etanol Hidratado. Os valores observados em verde no Gráfico 7 seguem uma tendência variável, mantendo-se positiva até 2018, depois tornando-se negativa até 2021.

Os valores do Etanol Anidro foram previstos pelo método ARCH, com o auxílio do software @RISK. Ao examinarmos os valores previstos, nota-se que a distribuição dos dados permanece com a sazonalidade analisada anteriormente na série, com um pequeno aumento da quantidade produzida a partir de 2021.

**Gráfico 8 – Histórico e previsão da emissão de CO<sub>2</sub> veicular**

Fonte: Autoria própria, 2021.



Ao analisarmos o Gráfico 8, pode-se observar que a emissão de CO<sub>2</sub> pelos veículos apresenta uma distribuição sazonal, com grande variação durante o período analisado.

Diferente das demais variáveis, a previsão do CO<sub>2</sub> foi realizada com base na Equação (26), visto que as variáveis necessárias para o cálculo foram previstas anteriormente pelos métodos AR, ARCH e ARMA. Os valores previstos do CO<sub>2</sub> permanecem com a característica sazonal da série, porém agora com uma tendência negativa.

## 4.2 PREVISÃO DA VARIÁVEL DEPENDENTE

O estudo de previsão da variável dependente não pode ser realizado sem a realização de um estudo estatístico prévio da base de dados, desta forma este tópico será dividido em duas seções, sendo a primeira destinada ao estudo estatístico e validação da série histórica e a segunda para a previsão da variável dependente.

### 4.2.1 Estudo estatístico

Antes de realizar a previsão da quantidade de licenciamentos de veículos com motor elétrico, primeiro foi necessário realizar um estudo estatístico da base de dados, a fim de validar a base de dados.

O primeiro tópico levantado foi a correlação entre as variáveis independentes com a variável dependente. Com auxílio do *software* SPSS e utilizando o método de regressão linear, foram calculados os índices de correlação individuais das variáveis.

**Tabela 4 – Correlações individuais entre as variáveis**

Correlação Independente		
Correlação	Variável dependente / independente	Licen. Elétrico
Correlação de Pearson	Licen. Gasolina	-,463
	Licen. Flex	-,262
	Licen. Diesel	,473
	Prod. Gasolina (m <sup>3</sup> )	-,474
	Prod. Diesel (m <sup>3</sup> )	-,323
	Prod. Etanol hidratado (m <sup>3</sup> )	,183
	Prod. Etanol Anidro (m <sup>3</sup> )	-,016

Correlação Independente		
Correlação	Variável dependente / independente	Licen. Elétrico
Correlação de Pearson	Emissão CO2	-,097

Fonte: Autoria Própria.

Ao analisarmos a Tabela 4, nota-se que as variáveis apresentam um índice de correlação de baixo a moderado. Se levarmos em consideração o grau de correlação calculado, a previsão do número de veículos licenciados com motores elétricos não seria justificada, contudo, para séries históricas multivariadas também deve-se levar em consideração a correlação múltipla das variáveis.

Desse modo, o SPSS também calculou índice de correlação múltipla (R) entre as variáveis, com valor de 0,807, ou seja, ao analisarmos a série histórica como um todo, as variáveis independentes juntas apresentam 80,7% de correlação com a variável dependente, justificando assim a previsão dos dados.

O método de regressão linear também fornece os coeficientes para realizar o cálculo da equação da reta, que pode ser escrita da seguinte forma:

$$Y = 247,09 + 0,023x_1 - 0,011x_2 + 0,18x_3 - 0,001x_4 + 0,00037x_5 - 0,0003x_6 + 0,00042x_7 + 0,000002x_8 \quad [26]$$

Onde,  $x_1$  é a quantidade de veículos licenciados com motor a gasolina,  $x_2$  é a quantidade de veículos licenciados com motor *flex*,  $x_3$  é a quantidade de veículos licenciados com motor a diesel,  $x_4$  é a quantidade de gasolina produzida por m<sup>3</sup>,  $x_5$  é a quantidade de diesel produzida por m<sup>3</sup>,  $x_6$  é a quantidade de etanol hidratado produzido por m<sup>3</sup>,  $x_7$  é a quantidade de etanol anidro produzido por m<sup>3</sup> e  $x_8$  é a quantidade de CO<sub>2</sub> emitido pelos veículos.

#### 4.2.2 Previsão do licenciamento dos veículos elétricos

Com a base de dados atendendo todos os pré-requisitos estatísticos, tornou-se possível realizar o estudo de previsão da variável dependente. Os métodos de previsão utilizados foram o ARIMA e o MLP, utilizando os softwares SPSS e Palisade NeuralTools, respectivamente.

Dentre os modelos de previsão utilizados, o que apresentou o melhor resultado de previsão foi o modelo ARIMA, com menor taxa de erros comparado ao modelo MLP, conforme representado na Tabela 4.

**Tabela 4 – Erros de previsão por tipo de modelo**

ARIMA		MLP	
% Erro	29,90%	% Erro	47,06%
RMSE	85,50	RMSE	180,89
MAE	165,75	MAE	297,19

Fonte: Autoria Própria.

O *software* SPSS utiliza um algoritmo de testes para definição da melhor configuração do modelo ARIMA a ser utilizada, o qual definiu como ARIMA(0,1,1) a melhor configuração para previsão do licenciamento de carros elétricos.

O número de licenciamento de veículos com motor elétrico é representado por uma distribuição não sazonal e com tendência fortemente positiva, com maior crescente a partir de 2019. O resultado da previsão pode ser observado no Gráfico 9.

**Gráfico 9 – Histórico e previsão do licenciamento de carros com motor elétrico**



Fonte: Autoria própria, 2021.

Ao analisar o gráfico, é possível observar que a quantidade de veículos licenciados apresentou uma média muito baixa no período de 2012 até março de 2019, o aumento repentino de licenciamentos pode ser justificado pelo início do projeto Rota 2030.

A mudança repentina no comportamento da série história (2012-2019) e a baixa quantidade de variáveis disponíveis para estudo podem dificultar a aplicação do método de previsão, podendo ocasionar erros de previsão e possíveis pontos fora da curva (outliers), como pode ser observado no valor previsto em junho de 2021.

De modo geral, podemos notar que o crescimento de veículos elétricos licenciados se manteve mesmo após a grande queda observada durante o período da pandemia do Covid-19, com previsão de crescimento constante e auge de 8726 unidades licenciadas no mês de dezembro de 2025.

## 5 CONCLUSÃO

Com a chegada do projeto de Lei 13.755 – Rota 2030 no final do ano de 2018, o número de veículos elétricos inseridos no mercado brasileiro passou a crescer em larga escala, tendo recorde de licenciamento mensal no mês de dezembro de 2019.

O objetivo deste trabalho foi comprovar a eficácia do Projeto Rota 2030, que mesmo tendo principal foco no incentivo na Pesquisa e Desenvolvimento (P&D) das montadoras, acabou impactando diretamente na quantidade de carros elétricos circulando no país.

Para que o Brasil esteja mais apto a adoção de uma maior frota de veículos elétricos, seria necessária a construção de mais postos de abastecimento elétrico, investimento em tecnologias nacionais para baratear os custos de fabricação dos veículos (como o intuito do Projeto Rota 2030), etc.

Ao analisarmos a série histórica do número de veículos elétricos licenciados no Brasil, é possível notar que a nova tecnologia ainda estava sendo implementada aos poucos no país, podendo se justificar pela complexidade de adaptar o mercado a utilização de carros elétricos.

A pandemia do Covid-19 impactou diretamente em todas as variáveis levantadas neste estudo, sendo visualmente perceptível a queda das mesmas nos gráficos a partir do início do ano de 2020, período em que a pandemia se iniciou no Brasil, com o impacto se estendendo até os últimos dados levantados na pesquisa.

Quando analisado o resultado da previsão, podemos concluir também que a venda de veículos elétricos no país será capaz de se recuperar e superar os danos causados pela pandemia do Covid-19, continuando a crescente que foi iniciada no ano de 2019.

Os níveis de emissão veicular de CO<sub>2</sub> também apresentaram uma queda a partir de 2021, indicando que o aumento na frota de veículos elétricos teve um impacto significativo na redução desses valores.

O ARIMA se mostrou um método eficaz para a previsão de base de dados multivariadas, superando o modelo MLP que se baseia no sistema de redes neurais nesta pesquisa, apresentando uma previsão de dados que se comportou de acordo com a tendência e distribuição analisada na série histórica precedente.

## REFERÊNCIAS

AGIRRE-BASURKO, E; IBARRA-BERASTEGI, G; MADARIAGA, I. Regression and multilayer perceptron-based models to forecast hourly O3 and NO2 levels in the Bilbao área. **Environmental Modelling & Software**, Volume 21, p. 430-446, 2006.

ALMANSOUR, N. A; SYED, H. F; KHAYAT, N. R; ALTHEEB, R. K; JURI, R. E; ALHIYAFI, J; ALRASHED, S; OLATUNJI, S. O. Neural network and support vector machine for the prediction of chronic kidney disease: A comparative study. **Computers in Biology and Medicine**, Volume 109, p. 101-111, 2019.

ALMEIDA, I. T., **A Poluição Atmosférica por Material Particulado na Mineração a Céu Aberto**, Dissertação de Mestrado, Escola Politécnica da Universidade de São Paulo, SP, 1999.

AZUAGA, D. **Danos Ambientais Causados por Veículos Leves no Brasil**. 2000. 168 p. Dissertação (Mestrado) - Planejamento Energético, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2000.

BARAN, R. **A introdução de veículos elétricos no Brasil: Avaliação do impacto no consumo de gasolina e eletricidade**. 2012. 139 f. Tese (Doutorado) – Curso de Programa de Planejamento Energético, Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2012.

BARAN, R.; LEGEY, L. F. L. The introduction of vehicles in Brazil: Impacts on oil and electricity consumption. **Technological Forecasting & Social Change**, Volume 80, p. 907-917, 2013.

BARAN, R.; LEGEY, L. F. L. **Veículos elétricos: história e perspectivas no Brasil**. BNDES Setorial 33, p. 207-224, Rio de Janeiro, 2010.

BUSSAB, W; MORETTIN, P. A. **Estatística Básica**. 6. ed. Editora Saraiva, São Paulo, 2002.

BRASIL. **Lei n. 13.755, de 10 de dezembro de 2018**. Estabelece requisitos obrigatórios para a comercialização de veículos no Brasil; institui o Programa Rota 2030 - Mobilidade e Logística; dispõe sobre o regime tributário de autopeças não produzidas; e altera as Leis n.º 9.440, de 14 de março de 1997, 12.546, de 14 de dezembro de 2011, 10.865, de 30 de abril de 2004, 9.826, de 23 de agosto de 1999,

10.637, de 30 de dezembro de 2002, 8.383, de 30 de dezembro de 1991, e 8.989, de 24 de fevereiro de 1995, e o Decreto-Lei nº 288, de 28 de fevereiro de 1967. <[http://www.planalto.gov.br/ccivil\\_03/\\_ato2015-2018/2018/lei/L13755.htm](http://www.planalto.gov.br/ccivil_03/_ato2015-2018/2018/lei/L13755.htm)>. Acesso em 15 mai. 2019.

BRUCHÊZ, A; D'AVILA, A. A. F; FERNANDES, A. M; CASTILHOS, N. C; OLEA, P. M. **Metodologia de Pesquisa de Dissertações sobre Inovação: Análise Bibliométrica**. Conferências UCS - Universidade de Caxias do Sul, XV Mostra de Iniciação Científica, Pós-Graduação, Pesquisa e Extensão. 2015.

CABANEROS, S. M. S; CALAUTIT, J. K. S; HUGHES, B. R. Hybrid Artificial Neural Network Models for Effective Prediction and Mitigation of Urban Roadside NO<sub>2</sub> Pollution. **Energy Procedia**, Volume 142, p. 3524-3530, 2017.

DIAS, M. V. X.; HADDAD, J.; NOGUEIRA, L. H.; BORTONI, E. C.; CRUZ, R. A. P.; YAMACHITA, R. A.; GONÇALVES, J. L. The impact on electricity demand and emissions due to the introduction of electric cars in the São Paulo Power System. **Energy Policy**, Volume 65. p. 298–304, 2014.

DÍAZ-ROBLES, L. A; ORTEGA, J. C; FU, J. S; REED, G. D; CHOW, J. C; WATSON, J. G; MONCADA-HERRERA, J. A. A hybrid ARIMA and artificial neural networks model to forecast particulate matter in urban areas: The case of Temuco, Chile. **Atmospheric Environment**, Volume 42, p. 8331-8340, 2008.

DOMÍNGUEZ-SÁEZ, A; RATTÁ, G. A; BARRIOS, C. C. Prediction of exhaust emission in transient conditions of a diesel engine fueled with animal fat using Artificial Neural Network and Symbolic Regression. **Energy**, Volume 149, p. 675-683, 2018.

DOTSE, S; PETRA, M. I; DAGAR, L; SILVA, L. C. Application of computational intelligence techniques to forecast daily PM<sub>10</sub> exceedances in Brunei Darussalam. **Atmospheric Pollution Research**, Volume 9, p. 358-368, 2018.

DRUMM, F. C.; GELHARDT, A. E.; FERNANDES, G. D.; CHAGAS, P.; SUCOLOTTI, M. S.; KEMERICH, P. D. C. Poluição atmosférica proveniente da queima de combustíveis derivados do petróleo em veículos automotores. **REGET/UFSM**, Santa Maria, v. 18, n. 1, p. 66-78, abr. 2014.

EHLERS, R. S. **Análise de séries temporais**. 3. ed. Curitiba, 2005.

EPE. Balanço Energético Nacional. **BEN-2007 (ANEXO E)**. 2007. Disponível em: <<http://www.epe.gov.br/pt/resultado-de-busca?k=fatores%20de%20convers%C3%A3o>>. Acesso em: 26 Abr. 2019.

FONSECA, M. O. K. **O impacto do protecionismo no setor automobilístico brasileiro**: uma análise dos programas Inovar Auto e Rota 2030. 30 p. Monografia (Pós-Graduação) – Ciências Econômicas, Instituto de Ensino e Pesquisa. São Paulo, 2018.

FRANCESCHI, F; COBO, M; FIGUEREDO, M. Discovering relationships and forecasting PM 10 and PM 2.5 concentrations in Bogotá, Colombia, using Artificial Neural Networks, Principal Component Analysis, and k-means clustering. **Atmospheric Pollution Research**, Volume 9, p. 912-922, 2018.

FRANZ, C. M.; SEBERINO, J. R. V. **A história do trânsito e sua evolução**. 2012. 24 f. Monografia (Pós-Graduação) – Curso de Pós-Graduação Lato Sensu em Gestão, Educação e Direito de Trânsito. Joinville, 2012.

FREITAS, J. C. N. **Projeto e análise ao funcionamento de carros elétricos**. 2012. 201 p. Dissertação (Mestrado)- Engenharia Mecânica, Universidade do Minho. Guimarães, 2012.

GAO, M; YIN, L; NING, J; Artificial neural network model for ozone concentration estimation and Monte Carlo analysis. **Atmospheric Environment**, Volume 184, p. 129-139, 2018.

GAO, Y; JI, H. Microscopic morphology and seasonal variation of health effect arising from heavy metals in PM<sub>2.5</sub> and PM<sub>10</sub>: One-year measurement in a densely populated area of urban Beijing. **Atmospheric Research**, Volume 212, p. 213-226, 2018.

GIL, A. C. **Métodos e Técnicas de Pesquisa Social**. 6. ed. São Paulo: Atlas, 2008.

GKIOULEKAS, I; PAPAGEORGIU, L. G. Piecewise Regression through the Akaike Information Criterion using Mathematical Programming. **IFAC-PapersOnline**, Volume 51, p. 730-735, 2018.

GUIMARÃES, E. A. A. A dinâmica de crescimento da indústria de automóveis no Brasil: 1957/78. **Pesquisa e Planejamento Econômico**, Rio de Janeiro, v. 10, n. 3, p.775-812, dez. 1980.



HAYKIN, S. **Neural Networks and Learning Machines**. Ontario, Canada. 3<sup>o</sup> edição: Prentice Hall, 2008.

HE, B.-Q.; SHUAI, S.-J.; WANG, J.-X.; HE, H. The effect of ethanol blended diesel fuels on emissions from a diesel engine. **Elsevier**, v. 37, n. 35, p. 4965-4971, nov. 2003.

HOFFMAN, R. **Análise de Regressão: Uma Introdução à Econometria**. Portal de Livros Abertos da USP. Volume 5, Piracicaba, 2016.

IBAMA. Programa de controle da poluição do ar por veículos automotores – **Proconve/Promot**. 3. ed. Brasília: Ibama, 2011. 584 p. (Coleção Meio Ambiente. Série Diretrizes – Gestão Ambiental, n.º 3).

IPCC. Volume 2 (Energy) - Guidelines for National Greenhouse Gas Inventories. **Chapter 1 – Introduction**. 2006. Disponível em: < <https://www.ipcc-nggip.iges.or.jp/public/2006gl/vol2.html>>. Acesso em: 26 abr. 2019.

ISLAM, M. N.; SIVAKUMAR, B. Characterization and prediction of runoff dynamics: a nonlinear dynamical view. **Advances in Water Resources**, Volume 25, p. 179-190, 2002.

JANUS, J. The COVID-19 shock and long-term interest rates in emerging market economies. **Finance Research Letters**, 101976, 2021.

LIMA, F. L. M.; SOARES, I. F. M.; COSTA, M. M. S. G.; SILVA, N. F. P. M.; SOUSA, P. J. S. C. P. **Motores de combustão interna**. Faculdade de Engenharia Universidade do Porto, Portugal, 2019.

LIMA-JUNIOR, F. R; CARPINETTI, L. C. R. Predicting supply chain performance based on SCOR® metrics and multilayer perceptron neural networks. **International Journal of Production Economics**, Volume 212, p. 19-38, 2019.

LUCAS, J. M.; SACCUCCI, M. S. Exponentially Weighted Moving Average Control Schemes: Properties and Enhancements, **Technometrics**, Volume 32, p. 1-12, 1990.

MARTINS, L. D.; SILVA, I.; BATISTA, W. V.; ANDRADE, M. F.; FREITAS, E. D.; MARTINS, J. A. How socio-economic and atmospheric variables impact COVID-19 and influenza outbreaks in tropical and subtropical regions of Brazil. **Environmental Research**, Volume 191, 2020.

MEDEIROS, T. G. G.; ANDRADE, C. F.; LINS, D. R. Avaliação de métodos de estimação de parâmetros de distribuições estatísticas aplicadas na análise de velocidade e direção do vento. **VIII Congresso Brasileiro de Energia Solar**. Volume 1, 2020.

MELO, V. A. O automóvel, o automobilismo e a modernidade no Brasil (1891-1908). **Revista Brasileira de Ciências do Esporte**, Campinas, 2008, v. 30, n. 1, p. 187-203, set. 2008.

MIGUEL, P. A. C.; FLEURY, A.; MELLO, C. H. P.; NAKANO, D. N.; TURRIONI, J. B.; HO, L. L.; MORABITO, R.; MARTINS, R. A.; PUREZA, V. **Metodologia de pesquisa em engenharia de produção e gestão de operações**. 2. ed. Rio de Janeiro: Elsevier, 2012.

MILLS, T. C. Seasonality and Exponential Smoothing – Chapter 9. **Applied Time Series Analysis**, Academic Press, p. 145-160, 2019.

MONTGOMERY, D. C.; JENNINGS, C. L.; KULAHCI, M. **Introduction to Time Series Analysis and Forecasting**, 2. ed. Wiley Series in Probability and Statistics, Wiley, New Jersey, USA, 2015.

MOON, J.; HOSSAIN, M. B.; CHON, K. H. AR and ARMA model order selection for time-series modeling with ImageNet classification. **Signal Processing**, Volume 183, 108026, 2021.

NOCE, T. **Estudo do funcionamento de veículos elétricos e contribuições ao seu aperfeiçoamento**. 127 p. Dissertação (Mestrado)- Programa de Pós-Graduação em Engenharia Mecânica, Pontifca Universidade Católica de Minas Gerais Belo Horizonte. Belo Horizonte, 2009.

PARMEZAN, A. R. S; SOUZA, V. M. A; BATISTA, G. E. A. P. A. Evaluation of statistical and machine learning models for time series prediction: Identifying the state-of-the-art and the best conditions for the use of each model. **Information Sciences**, Volume 484, p. 302-337, 2019.

PEREIRA, B. S. **Controle de Mistura Ar/Combustível em um Motor a Combustão Interna: Sistema em Malha Fechada**. 92 p. Dissertação (Mestrado)- Engenharia de Sistemas Eletrônicos, Escola Politécnica da Universidade de São Paulo. São Paulo, 2015.

REIKARD, G. Volcanic emissions and air pollution: Forecasts from time series models. **Atmospheric Environment: X**, Volume 1, 2019.

RODRIGUES, R. L.; MEDEIROS, F. P. A.; GOMES, A. S. Modelo de Regressão Linear aplicado à previsão de desempenho de estudantes em ambiente de aprendizagem. **XXIV Simpósio Brasileiro de Informática na Educação**, Volume 1, Campinas, 2013.

RODRIGUES, S. C. A. **Modelo de Regressão Linear e suas Aplicações**. Relatório (Mestrado) – Ciências, Universidade da Beira Interior. Covilhã, 2012.

ROITMAN, V. L. **Um modelo computacional de redes neurais para predição do índice de desemprego aberto**. Tese de Pós-Graduação da Universidade Federal do Rio de Janeiro, 2001.

ROTA 2030. **O que é o Rota 2030?** Disponível em: <<https://www.rota2030.com.br/rota-2030-inovacao/>>. Acesso em: 13 mai. 2019.

SAMOLOV, A; DRAGOVIC, S; DAKOVIC, M; BACIC, G. Analysis of <sup>7</sup>Be behaviour in the air by using a multilayer perceptron neural network. **Journal of Environmental Radioactivity**, Volume 137, p. 198-203, 2014.

SILVA, T. L. O.; VELOSO, L. G. Cenário macroeconômico e automobilístico no período de 2014 a 2017, e os impactos da Rota 2030. In: IV CONGRESS OF INDUSTRIAL MANAGEMENT AND AERONAUTICAL TECHNOLOGY. 10., 2017, São José dos Campos. **Anais do IV CIMATech**, São José dos Campos: FATEC-SJC, 2017.

SILVA, W. S.; SÁFADI, T.; JÚNIOR, L. G. C. Uma análise empírica da volatilidade do retorno de commodities agrícolas utilizando modelos ARCH: os casos do café e da soja. **Revista de Economia e Sociologia Rural**, Volume 48, p. 119-134, 2005.

SIQUEIRA, D. A.; SIQUEIRA, A. A. Estudo e Avaliação da Tecnologia Flex Fuel. **Associação Brasileira de Engenharia e Ciências Mecânicas**, 2004.

SOUZA, L. P.; LORA, E. E. S.; PALACIO, J. C. E.; ROCHA, M. H.; RENÓ, M. L. G. Análise do ciclo de vida de veículos convencional, elétrico e híbrido plug-in para condições brasileiras. **Revista Ibero-Americana de Ciências Ambientais**, Volume 7, p.144-159, 2016.

SOUZA, S. G. **Um estudo sobre a evolução das câmaras de combustão dos motores do ciclo Otto à gasolina e sua aplicação ao etanol hidratado como combustível alternativo**. 174 p. Dissertação (Mestrado)- Engenharia Mecânica, Universidade de São Paulo. São Carlos, 2004.

SUHERMI, N; SUHARTONO; PRASTYO, D. D; ALI, B. Roll motion prediction using a hybrid deep learning and ARIMA model. **Procedia Computer Science**, Volume 144, p. 251-258, 2018.

SU, Y; GAO, W; GUAN, D; SU, W. Dynamic assessment and forecast of urban water ecological footprint based on exponential smoothing analysis. **Journal of Cleaner Production**, Volume 195, p. 354-364, 2018.

SYNTETOS, A. A; BABAI, M. Z; GARDNER, E. S. Forecasting intermittent inventory demands: simple parametric methods vs. Bootstrapping. **Journal of Business Research**, Volume 68, p. 1746-1752, 2015.

TANEJA, K; AHMAD, S; AHMAD, K; ATTRI, S. D. Time series analysis of aerosol optical depth over New Delhi using Box e Jenkins ARIMA modeling approach. **Atmospheric Pollution Research**, Volume 7, p. 585-596, 2016.

TANG, H; DONG, P; SHI, Y. A new approach of integrating piecewise linear representation and weighted support vector machine for forecasting stock turning points. **Applied Soft Computing**, Volume 78, p. 685-696, 2019.

TANG, J; CHEN, X; HU, Z; ZONG, F; HAN, C; LI, L. Traffic flow prediction based on combination of support vector machine and data denoising schemes. **Physica A: Statistical Mechanics and its Applications**, 2019.

TEIXEIRA, E. C; FELTES, S; SANTANA, E. R. R. Estudo Das Emissões De Fontes Móveis Na Região Metropolitana De Porto Alegre, Rio Grande Do Sul. **Química Nova**, v. 31, p. 244, 2008.

VONBUN, C. Impactos ambientais e econômicos dos veículos elétricos e híbridos plug-in: uma revisão da literatura. **[SYN]THESIS**, Rio de Janeiro, v. 8, n. 2, p. 45-63, 2015.

VU, H. L; BOLINGBROKE, D; WAI NG, K. T; FALLAH, B. Assessment of waste characteristics and their impact on GIS vehicle collection route optimization using ANN waste forecasts. **Waste Management**, Volume 88, p. 118-130, 2019.

WANG, D; LU, W. Ground-level ozone prediction using multilayer perceptron trained with an innovative hybrid approach. **Ecological Modelling**, Volume 198, p. 332-340, 2006.

WERNECK, G. L.; CARVALHO, M. S. A pandemia do COVID-19 no Brasil: crônica de uma crise sanitária anunciada. **Cad. Saúde Pública**, Volume 35, p. 5, 2020.

WOMACK, J. P.; JONES, D. T.; ROOS, D. **A Máquina que mudou o mundo**. 5. ed. Campus, 2004.

XU, G; SCHWARZ, P; YANG, H. Determining China's CO2 emissions peak with a dynamic nonlinear artificial neural network approach and scenario analysis. **Energy Policy**, Volume 128, p. 752-762, 2019.

YANG, Z.; CE, L.; LIAN, LI. Electricity price forecasting by a hybrid model, combining wavelettransform, ARMA and kernel-based extreme learning machine methods. **Applied Energy**, Volume 190, p. 291-305, 2017.

YUSRI, I. M; MAJEED, A. P. P. A; MAMAT, R; GHAZALI, M. F; AWAD, O. I; AZMI, W, H. A review on the application of response surface method and artificial neural network in engine performance and exhaust emissions characteristics in alternative fuel. **Renewable and Sustainable Energy Reviews**, Volume 90, p. 665-686, 2018.

ZAFRA, C; ÁNGEL, Y; TORRES, E. ARIMA. Analysis of the effect of land surface coverage on PM10 concentrations in a high-altitude megacity. **Atmospheric Pollution Research**, Volume 8, p. 660-668, 2017.

ZHANG, L; LIN, J; QIU, R; HU, X; ZHANG, H; CHEN, Q; TAN, H; LIN, D; WANG, J. Trend analysis and forecast of PM 2.5 in Fuzhou, China using the ARIMA model. **Ecological Indicators**, Volume 95, p. 702-710, 2018.

### ANEXO A – DADOS UTILIZADOS

Data	Gasolina	Flex	Diesel	Gasolina (m <sup>3</sup> )	Diesel (m <sup>3</sup> )	Etanol hidratado (m <sup>3</sup> )	Etanol anidro (m <sup>3</sup> )	CO2	Elétrico
01/01/2012	24554	211422	16687	2189964	3589974	215417	142353	346689670	9
01/02/2012	21040	202970	11819	2060189	3586242	153762	117957	335701773	16
01/03/2012	26766	243878	13138	2227777	3765604	157582	82780	354592194	7
01/04/2012	23948	209603	11035	2211711	3639882	486832	93392	358764432	3
01/05/2012	25007	233619	15660	2211169	3851406	1484497	632525	427208369	13
01/06/2012	23218	301201	16177	2138433	3868281	1356986	897393	429306479	23
01/07/2012	23876	309415	20134	2190185	3863872	1975511	1483775	476599324	5
01/08/2012	27034	358307	20134	2270505	3890241	2177694	1685758	497760845	3
01/09/2012	20789	240344	16550	2146593	3935916	1970478	1544251	480252949	2
01/10/2012	20689	286885	19455	2199188	3726888	1849515	1562537	467740828	2
01/11/2012	18277	261382	17404	2122852	3844061	1342562	1105844	434369035	18
01/12/2012	18717	303848	21286	2262254	3941638	675193	564079	403548668	16
01/01/2013	16470	262500	18174	2305142	4121917	141123	171445	382226631	45
01/02/2013	12085	196783	13841	1981895	3662052	96353	88130	332225589	22
01/03/2013	12900	238798	16838	2218077	4263753	128890	85009	381493233	53
01/04/2013	16832	281017	19084	2338883	4114048	1158513	413436	429645425	50
01/05/2013	15520	266921	18490	2547099	4316592	1902831	1341296	515393741	12
01/06/2013	14782	269444	18830	2386944	3969111	1638216	1224194	472173736	29
01/07/2013	16426	287838	19968	2539279	4313743	2071341	1736499	535797700	65
01/08/2013	16033	278169	18758	2547379	4421952	2246731	1841115	552735994	45
01/09/2013	15145	260499	18750	2421396	3968272	2058596	1624180	504451882	23
01/10/2013	17795	275871	20172	2548704	4051871	1840086	1521859	504944858	39
01/11/2013	16755	253941	17799	2444939	4178500	1571002	1199931	484184764	52
01/12/2013	18366	297333	20478	2333635	4157375	864834	562220	426830079	56
01/01/2014	17064	265570	17378	2325547	3918413	146790	175157	372159401	93

Data	Gasolina	Flex	Diesel	Gasolina (m <sup>3</sup> )	Diesel (m <sup>3</sup> )	Etanol hidratado (m <sup>3</sup> )	Etanol anidro (m <sup>3</sup> )	CO2	Eléctrico
01/02/2014	14891	216144	15042	2201106	3587514	129510	109318	342853210	61
01/03/2014	13144	201145	14774	2405370	4268645	217352	155518	398638824	65
01/04/2014	16010	245955	18105	2310722	4189359	1053833	533507	433047263	53
01/05/2014	15875	243898	18542	2429498	4001846	1829308	1436229	491458641	94
01/06/2014	13864	221487	15612	2458857	4231069	2045085	1609175	520592644	52
01/07/2014	14952	247045	18133	2485203	4437779	2016924	1506337	529030291	61
01/08/2014	14656	228445	16311	2573642	4198106	2502431	1888443	552529531	79
01/09/2014	15981	249241	17591	2417478	4089690	2251524	1489743	513032935	71
01/10/2014	15899	258428	17433	2453624	4296071	2290391	1572794	531475961	53
01/11/2014	14654	248154	17265	2445875	4220215	1357565	854802	465864729	87
01/12/2014	17851	314996	21093	2364964	4236351	630057	413314	419070213	86
01/01/2015	12900	217010	14285	2185201	3860184	207021	196171	363558731	72
01/02/2015	10123	158500	10584	2026243	3522225	178650	146990	332050570	56
01/03/2015	12830	198763	14682	1959332	4068457	357271	153335	365974365	61
01/04/2015	12424	185852	13653	2017156	3979112	1315458	537824	413409374	73
01/05/2015	11866	180471	12825	2277917	4427701	2051461	1004755	498557436	72
01/06/2015	11681	181203	11940	2163185	4254604	2348174	1360621	506106641	74
01/07/2015	11818	194484	13322	2214111	4269605	2246458	1424321	508690895	74
01/08/2015	10903	177859	11247	1998893	4317505	2786357	1828723	533560282	100
01/09/2015	10926	169869	11970	2179941	4470985	2341271	1467219	523218336	82
01/10/2015	10421	164256	10752	2264801	4411377	2370752	1561256	529423956	55
01/11/2015	8953	170039	10493	2156774	3917719	1411569	1053239	441068133	65
01/12/2015	11305	195714	13764	2284630	3958134	996256	654720	420824691	62
01/01/2016	7494	132454	9828	2246717	4340058	311344	195907	398310857	58
01/02/2016	6631	125415	10148	2146908	3737505	234915	105364	351882727	64
01/03/2016	8019	151120	14190	2292737	3917051	696079	219495	391663554	60
01/04/2016	6105	138772	12807	2301414	3923990	1831197	944618	460971126	137
01/05/2016	6142	143453	12712	2212156	3896197	1957896	1313018	472643001	41

Data	Gasolina	Flex	Diesel	Gasolina (m <sup>3</sup> )	Diesel (m <sup>3</sup> )	Etanol hidratado (m <sup>3</sup> )	Etanol anidro (m <sup>3</sup> )	CO2	Eléctrico
01/06/2016	6182	146579	13763	2084140	3924724	1891285	1326582	464855234	91
01/07/2016	6033	155281	13661	2220364	3705479	2354444	1779623	494203161	48
01/08/2016	6423	158124	13669	2110612	3863525	2294996	1578171	487008104	59
01/09/2016	7273	134957	12757	2091386	3595229	2125072	1563016	463861561	49
01/10/2016	6719	136193	12004	2336556	3971110	1711501	1371879	477556456	93
01/11/2016	6363	153445	13779	2193446	3417354	1133851	893317	398599747	159
01/12/2016	7111	174955	16945	2277795	3077585	490173	370506	341162511	202
01/01/2017	4678	127106	11806	2225324	3318375	176039	130973	331418921	178
01/02/2017	4337	117500	10632	2055686	3092889	174585	87152	306875109	157
01/03/2017	5870	164203	13888	2362086	3513442	424559	223572	363060356	227
01/04/2017	5083	134570	12809	2276696	3472409	1171443	549015	394973643	176
01/05/2017	5953	169784	14445	2082411	3497701	1633807	1225869	427284314	208
01/06/2017	5801	168394	15050	2140168	3316044	1934382	1566560	444047402	238
01/07/2017	5609	157115	16046	2377471	3393470	2483298	1940256	496359208	268
01/08/2017	6746	186474	16295	2229021	3358185	2302402	1612691	466705949	627
01/09/2017	6065	173628	13729	2134015	3419821	2562815	1799897	481120351	384
01/10/2017	5812	174369	16518	2197570	3521321	2055823	1397033	457108852	243
01/11/2017	5961	175425	16021	1957103	3385743	1379836	812017	388715429	240
01/12/2017	6987	178653	19328	2177004	3291800	653276	295845	350528450	350
01/01/2018	5937	154303	15345	2098028	2935542	210769	120161	302940150	272
01/02/2018	5346	133063	13331	1881801	2778261	202000	60160	278674184	254
01/03/2018	6946	176364	16717	1919762	3295836	601179	93138	326096707	367
01/04/2018	7138	184670	18066	2002773	3357618	2103520	614308	408450506	367
01/05/2018	7376	169788	17825	2098177	3844612	2683584	1150399	483056548	302
01/06/2018	7471	168803	18714	2058398	3749212	3106391	1453134	501987935	382
01/07/2018	7045	181446	20321	1998720	3945233	3467254	1626952	529266821	262
01/08/2018	7640	211318	20379	1908901	3651888	3189846	1389628	488261909	262
01/09/2018	5907	179813	19128	1964622	3452534	3005459	1190928	465991733	286



Data	Gasolina	Flex	Diesel	Gasolina (m <sup>3</sup> )	Diesel (m <sup>3</sup> )	Etanol hidratado (m <sup>3</sup> )	Etanol anidro (m <sup>3</sup> )	CO2	Eléctrico
01/10/2018	7356	216671	20730	2033265	3836864	2358395	936170	458958543	405
01/11/2018	6738	196776	17921	1833040	3587101	1653530	606931	395042448	374
01/12/2018	7032	195161	22801	1854794	3445764	1030540	202063	350454731	437
01/01/2019	5832	167381	17626	1949930	3181084	222912	134678	309234190	370
01/02/2019	6053	167760	16173	1899733	3077530	159728	67533	295555788	287
01/03/2019	5750	175578	18310	2001491	3557531	475044	106876	341796038	336
01/04/2019	6311	194518	20600	1925266	3490988	1840038	422949	394756897	290
01/05/2019	6196	206391	21656	1940084	3539143	2803537	1247646	464344772	357
01/06/2019	5946	186549	20786	1980570	3477501	3082970	1515286	483415346	716
01/07/2019	5962	202674	23266	2225349	3510408	3431251	1552913	513676005	960
01/08/2019	6481	201829	22345	2192071	3606868	3812154	1568563	531569460	867
01/09/2019	6533	194701	21516	1927449	3371250	3567672	1337736	485020159	1264
01/10/2019	6378	210454	22965	1941873	3285598	3345095	1412504	475770769	1989
01/11/2019	5713	202685	21179	1869709	3317434	1662492	805904	389657190	2013
01/12/2019	6698	218130	24800	2034543	3499512	496285	235232	346047722	2409
01/01/2020	4629	158721	19764	1918541	3386057	324016	151268	323362618	1568
01/02/2020	5383	167375	18488	1822063	3282044	307233	76486	308324950	2053
01/03/2020	4005	135044	15685	1728705	3203624	631824	142181	312568310	1570
01/04/2020	1292	41142	8587	1186221	2620803	2008355	616231	315060723	442
01/05/2020	2349	44734	9021	1541303	3342669	2660895	1076595	418082166	601
01/06/2020	5389	102259	13813	1691989	3559991	2735549	1185302	446142700	1334
01/07/2020	5829	138040	17887	1896259	3842899	3219532	1469565	502511576	1668
01/08/2020	5882	148276	17721	1994745	4018009	3204638	1451206	517058613	1943
01/09/2020	6459	168352	22241	2003893	3859881	3194986	1613819	514373325	2113
01/10/2020	5909	175742	21775	1904667	3992985	2496346	1465604	485306606	2273
01/11/2020	5763	184524	21968	1952633	3556047	1315922	773911	394421306	2231
01/12/2020	6041	200790	24204	2062302	3550113	455806	227359	348806917	1949
01/01/2021	3891	138279	19089	2145075	3502674	312560	142924	342599863	1321

