

**UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ**

**WILLIAM RICARDO ROSA**

**USO DE REDES NEURAS ARTIFICIAIS NO CONTROLE DE QUALIDADE DA  
GASOLINA – UMA REVISÃO SISTEMÁTICA DA LITERATURA**

**FRANCISCO BELTRÃO**

**2022**

**WILLIAM RICARDO ROSA**

**USO DE REDES NEURAS ARTIFICIAIS NO CONTROLE DE QUALIDADE DA  
GASOLINA – UMA REVISÃO SISTEMÁTICA DA LITERATURA**

**Use of artificial neural networks in gasoline quality control - a  
systematic review of the literature**

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

Orientador: Claiton Zanini Brusamarello

**FRANCISCO BELTRÃO**

**2022**



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

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

**WILLIAM RICARDO ROSA**

**USO DE REDES NEURAS ARTIFICIAIS NO CONTROLE DE QUALIDADE DA  
GASOLINA – UMA REVISÃO SISTEMÁTICA DA LITERATURA**

Trabalho de Conclusão de Curso de Graduação  
apresentado como requisito para obtenção do título de  
Bacharel em Engenharia Química da Universidade  
Tecnológica Federal do Paraná (UTFPR).

Data de aprovação: 12 de dezembro de 2022

---

Claiton Zanini Brusamarello  
Doutorado em Engenharia Química  
Universidade Tecnológica Federal do Paraná

---

Andriele De Pra Carvalho  
Doutorado em Administração  
Universidade Tecnológica Federal do Paraná

---

Silvane Morés  
Doutorado em Química  
Universidade Tecnológica Federal do Paraná

“A folha assinada encontra-se na Coordenação do Curso”

**FRANCISCO BELTRÃO**

**2022**

Dedico este trabalho aos meus pais Ricardo e  
Marcia, por todo apoio.

## AGRADECIMENTOS

À Deus, por me dar forças em todos momentos, sempre guiando meus passos e fornecendo apoio nos momentos de dificuldade que passei nesta trajetória.

A meus avós, e meus pais, Ricardo e Marcia, que foram pessoas extremamente importantes e nunca deixaram de acreditar em meus sonhos. Ambos buscaram sempre me incentivar a não desistir dos objetivos que tenho traçado em minha vida, trabalhando e me aconselhando sobre várias decisões importantes que tive que tomar durante esta jornada. Vocês sempre foram empenhados em me fornecer uma boa educação e nunca deixaram de se esforçar para me ajudar, incentivar e cooperar com meu aprendizado. Vocês são exemplos de humildade, dedicação, empatia e bondade, por isso essa conquista também é de vocês.

Ao meu orientador Prof. Dr. Claiton Zanini Brusamarello, por ter aceitado o convite, além de disponibilizar sua experiência na área, realizando correções e explicando de forma objetiva os conceitos que precisei adquirir para realização desta pesquisa. Além da orientação, agradeço pela amizade que foi construída, confiando desde o início no desenvolvimento do nosso trabalho e acreditando na minha capacidade. Obrigado por todo apoio.

Aos membros da banca Prof. Dr<sup>a</sup> Andriele De Pra Carvalho e Prof. Dr<sup>a</sup> Silvane Morés, por aceitar o convite e disponibilizar seu tempo para avaliação deste trabalho, pelas considerações fornecidas no TCC1, às quais pude avaliar e aperfeiçoar durante a elaboração deste trabalho final. E também a Universidade Tecnológica Federal do Paraná (UTFPR) e o seu corpo docente que demonstrou estar comprometido com a qualidade e excelência do ensino.

Aos meus amigos de infância, Mateus, Marcelo, Fábio, Luan e Ana Mattia, que mesmo longe, sempre estiveram presentes ouvindo e apoiando minhas decisões. Em especial meu amigo, mestrando, Paulo Victor Bussad Meireles que além de me apoiar a distância durante anos, sendo um irmão que não tive antes, e que nunca mediu esforços para me escutar e me aconselhar em todos momentos, me instruindo sobre princípios acadêmicos importantes. Gratidão a todos vocês que marcaram minha vida de alguma forma.

A todos que fizeram parte da construção do conhecimento que pude adquirir, bem como minha formação, muito obrigado.

Devemos acreditar que somos dotados de alguma coisa e que essa coisa deve ser alcançada a qualquer custo.

(CURIE, Marie).

## RESUMO

A presente monografia baseia-se nas principais lacunas e tendências acerca da temática - Aplicação de Redes Neurais Artificiais (RNAs), no controle de qualidade da gasolina e visa buscar os modelos de RNAs utilizados como alternativa para análise da qualidade da gasolina nos últimos 10 anos. Com isso, a proposta principal desta pesquisa é analisar os métodos de RNA que estão sendo utilizados para a inspeção de qualidade da gasolina por meio de uma revisão sistemática da literatura. A pesquisa foi conduzida por meio de uma revisão sistemática da literatura, utilizando o IEEE, Scopus e *ScienceDirect* como fontes de busca. Em relação a operacionalização e extração de artigos, foram utilizadas 3 *strings* de busca formadas pelas palavras-chave: *neural network*, *gasoline*, *octane number prediction*, *antiknock performance*, *density*. Os resultados encontrados nas bases de dados foram restringidos a publicações no período temporal dos últimos 10 anos (2012-2022) no idioma inglês, os quais foram submetidos a uma análise prévia, e a posteriori, selecionados para leitura na íntegra e introduzidos os critérios de exclusão e inclusão. Através da análise dos artigos que compuseram esta revisão sistemática da literatura, foi possível subdividi-los em duas categorias empíricas, ou seja, pesquisas que utilizaram uma RNA existente na literatura e pesquisas que buscaram introduzir modificações nos modelos de RNA presentes na literatura. Em seguida, os artigos foram sintetizados no intuito de explicitar as características principais de cada modelo, além de frisar os dados utilizados no processamento do modelo e compostos da gasolina previstos na análise por meio do uso de RNAs. Como conclusões, a pesquisa permitiu identificar quais os modelos de RNA e adaptações da estrutura são mais indicados para a análise da qualidade da gasolina, além de demonstrar que para obter resultados precisos as RNAs necessitam de algoritmos de treinamento adequado e modificações na estrutura.

Palavras-chave: rede neural; predição da octanagem; índice antidetonante; densidade.

## ABSTRACT

This monograph is based on the main gaps and trends on the subject - Application of Artificial Neural Networks (ANNs) in gasoline quality control and aims to find ANN models used as an alternative for analyzing the quality of gasoline in the last 10 years. Thus, the main purpose of this research is to analyze the ANN methods that are being used for gasoline quality inspection through a systematic review of the literature. The research was conducted through a systematic review of the literature, using the IEEE, Scopus and ScienceDirect as search sources. Regarding the operationalization and extraction of articles, 3 search strings formed by the keywords were used: neural network, gasoline, octane number prediction, antiknock performance, density. The results found in the databases were restricted to publications in the time period of the last 10 years (2012-2022) in the English language, which were submitted to a prior analysis, and posteriori, selected for reading in full and introduced the criteria of exclusion and inclusion. Through the analysis of the articles that composed this systematic review of the literature, it was possible to subdivide them into two empirical categories, that is, research that used an existing ANN in the literature, and research that sought to introduce modifications in the ANN models present in the literature. Then, the articles were synthesized in order to explain the main characteristics of each model, in addition to highlighting the data used in the processing of the model and gasoline compounds predicted in the analysis through the use of ANNs. As conclusions, the research allowed identifying which ANN models and structure adaptations are most suitable for the analysis of gasoline quality, in addition to demonstrating that to obtain accurate results, ANNs need adequate training algorithms and structure modifications.

Keywords: neural network; octane number prediction; antiknock performance; density.



## LISTA DE FIGURAS

Figura 1 – Representação simplificada de um rede neural artificial.....	26
Figura 2 – RNA <i>feedforward</i> ou acíclica.....	26
Figura 3 – RNA <i>feedback</i> ou cíclica.....	27
Figura 4 – Estrutura de uma RBF.....	31
Figura 5 – Estrutura da RNA BP com as fases de treinamento.....	32
Figura 6 – Arquitetura do modelo de rede neural <i>Backpropagation</i> .....	50
Figura 7 – Estrutura da rede neural .....	52
Figura 8 – Estrutura da rede neural BP ( <i>Backpropagation</i> ).....	53
Figura 9 – Estrutura do modelo de rede neural BP .....	56

## LISTA DE GRÁFICOS

<b>Gráfico 1 – Artigos encontrados nas bases de dados do IEEE .....</b>	<b>42</b>
<b>Gráfico 2 – Artigos encontrados nas bases de dados do <i>ScienceDirect</i>.....</b>	<b>43</b>
<b>Gráfico 3 – Artigos encontrados nas bases de dados do Scopus.....</b>	<b>43</b>
<b>Gráfico 4 – Artigos encontrados nas bases de dados .....</b>	<b>44</b>
<b>Gráfico 5 – Publicações da utilização de redes neurais na análise de qualidade da gasolina.....</b>	<b>49</b>

## LISTA DE ABREVIATURAS E SIGLAS

ABNT	Associação Brasileira de Normas Técnicas
ABNT NBR 14932	Produtos Líquidos de petróleo
AEAC	Álcool Etílico Anidro Combustível
AEE	<i>Average Absolute Error</i>
ANN	<i>Artificial Neural Network</i>
ANN BP	<i>Artificial Neural Network Backpropagation</i>
ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
ASTM	<i>American Society for Testing and Materials</i>
ASTM D1319	<i>Testing Method Fluorescence Indicator Absorption Method</i>
BP	<i>Backpropagation</i>
BI	Índice de ramificação
CIMA	Conselho Interministerial do Açúcar e do Álcool
C/Co	Concentração no tempo t dividida pela concentração inicial
ELU	<i>Exponential Linear Unit</i>
FACE	Combustíveis para motores de combustão avançados
FTIR	Espectroscopia de Infravermelho com Transformada de Fourier
GA	<i>Genetic Algorithm</i>
GA-BP	Rede Neural <i>Backpropagation</i> otimizada no algoritmo genético
IAA	Instituto do Açúcar e do Álcool
IAD	Índice Antidetonante
IEEE	Instituto de Engenheiros Eletricistas e Eletrônicos
INMETRO	Instituto Nacional de Metrologia, Qualidade e Tecnologia
LM	Levenberg-Marquardt
MAPA	Ministério da Agricultura, Pecuária e Abastecimento
MAE	<i>Mean Absolute Error</i>
MLP	<i>Multilayer Perceptron</i>
MON	<i>Motor Octane Number</i>
MPE	Erro Percentual Médio
MRE	<i>Mean Relative Error</i>
MSE	<i>Mean Square Error</i>
MW	Peso molecular
NIR	Espectrometria de Infravermelho Próximo
NMR	<i>Nuclear Magnetic Resonance</i>
PLS	<i>Partial Least Squares</i>
PLSR	<i>Partial Least Squares Regression</i>
PSO	<i>Particle Swarm Optimization</i>
R <sup>2</sup>	<i>Coefficiente of determination</i>
RBF	Rede Neural de Função de Base Radial
RBFT	Rede Neural de Função de Base Radial com função de transferência gaussiana
ReLU	<i>Rectified Linear Unit</i>
RSM	<i>Response Surface Methodology</i>
RMSE	<i>Root Mean Square Error</i>
RNA	Rede Neural Artificial
RNA BP	Rede Neural Artificial <i>Backpropagation</i>

RNAs	Redes Neurais Artificiais
RON	<i>Research Octane Number</i>
SGD	<i>Stochastic Gradient Descent</i>
TANSIG	Tangente Hiperbólica de Função Sigmoide
UTFPR	Universidade Tecnológica Federal do Paraná

## SUMÁRIO

<b>1 INTRODUÇÃO</b> .....	<b>14</b>
<b>2.1 Objetivo Geral</b> .....	<b>16</b>
<b>2.2 Objetivos Específicos</b> .....	<b>16</b>
<b>3 DESENVOLVIMENTO</b> .....	<b>17</b>
<b>3.1 Gasolina</b> .....	<b>17</b>
3.1.1 Composição química .....	18
3.1.2 Tipos de gasolina .....	18
3.1.3 Octanagem.....	19
3.1.4 Teor Alcoólico da Gasolina: contexto histórico.....	20
3.1.5 Legislação .....	20
3.1.5 Adulteração da gasolina .....	21
<b>3.2 Redes Neurais</b> .....	<b>23</b>
3.2.1 Definição .....	24
3.2.2 Arquitetura da RNA .....	25
3.2.3 Vantagens e desvantagens do uso de RNA.....	28
3.2.4 Aprendizado de RNAs .....	29
3.2.5 RNAs utilizadas na análise da qualidade da gasolina .....	29
3.2.6 Rede Neural de Função de Base Radial (RBF).....	30
3.2.7 Rede Neural <i>Backpropagation</i> (RNA BP).....	31
<b>4 PROCEDIMENTOS METODOLÓGICOS</b> .....	<b>34</b>
<b>4.1 Questões de Pesquisa</b> .....	<b>34</b>
<b>4.2 Seleção de Fontes</b> .....	<b>34</b>
<b>4.3 Palavras-Chave</b> .....	<b>35</b>
<b>4.4 Tipo dos Artigos</b> .....	<b>36</b>
<b>4.5 Idioma(s) dos Artigos</b> .....	<b>36</b>
<b>4.6 Critérios de Inclusão e Exclusão dos Trabalhos</b> .....	<b>36</b>
4.6.1 Critérios de Inclusão.....	36
4.6.2 Critérios de Exclusão.....	37
<b>4.7 Critérios de Qualidade dos Estudos Primários</b> .....	<b>37</b>
<b>4.8 Processo de Seleção dos Estudos Primários</b> .....	<b>37</b>
<b>4.9 Estratégia de Extração de Informação</b> .....	<b>38</b>
<b>4.10 Sumarização dos Resultados</b> .....	<b>38</b>

<b>5 RESULTADOS E DISCUSSÃO .....</b>	<b>40</b>
<b>5.1 Aspectos Relevantes Condizentes a Pesquisa .....</b>	<b>44</b>
<b>6 CONCLUSÃO .....</b>	<b>58</b>
<b>REFERÊNCIAS.....</b>	<b>59</b>
<b>APÊNDICE A.....</b>	<b>66</b>

## 1 INTRODUÇÃO

Segundo o trabalho de Takeshita (2006), a adulteração de combustíveis é um crime grave que ocorre de maneira excessiva no Brasil, e leva a Agência Nacional do Petróleo Gás e Biocombustíveis (ANP) reforçar as inspeções referentes a qualidade como forma de impedir estas ilegalidades. Dessa forma, entre os principais objetivos da ANP, destacam-se as demandas do Governo Federal para estabelecer a médio prazo uma política nacional de combustíveis que abrange duas vertentes: o da fiscalização (que está relacionado à adulteração de combustíveis) e o da qualidade do combustível distribuído e comercializado, nacionalmente (que está ligado à satisfação do consumidor). No entanto, embora a inspeção de combustíveis seja realizada com frequência por todo território brasileiro, e revendas irregulares são autuadas, o crime de adulteração é recorrente no país (MENESES, 2019).

De acordo com Chen *et al.* (2018), o método de análise deve ser preciso nos resultados e ser frequentemente utilizado na avaliação da qualidade da gasolina. Neste sentido, a ANP determina por meio da Resolução nº 807, de 23 de janeiro de 2020, uma série de critérios para o controle de qualidade da gasolina, conferidos pelo método de análise padrão (teste da proveta), como forma de padronizar a gasolina fornecida ao consumidor final. Porém, por estes testes serem feitos de forma manual por agentes da ANP, erros de análise podem ser cometidos.

Em decorrência destes problemas, a Rede Neural Artificial (RNA) surge como alternativa, por ser capaz de realizar seu treinamento de forma supervisionada através do algoritmo de retropropagação de erro, baseado na aprendizagem por correção de erros (BORSATO, *et al.* 2009). Neste sentido, caso esta alternativa fosse implementada aos métodos de análise da qualidade da gasolina regulamentados pelo Governo Federal, seria possível inibir as possíveis falhas humanas ocorridas durante os processos de inspeção, tornando a análise mais precisa, ou seja, com resultados mais consistentes e confiáveis, pois as RNAs são baseadas em princípios estatísticos cada vez mais utilizados no reconhecimento e classificação de padrões (FLECK *et al.*, 2016).

Em vista destes fatores, a pesquisa propõe-se a compor por meio de uma revisão sistemática da literatura, as lacunas e tendências com base nos modelos de RNA, acerca da temática - Aplicação de Redes Neurais Artificiais (RNAs) no controle

de qualidade da gasolina, para compreender o uso da Inteligência Artificial (IA) voltada para este segmento. E com isso, analisar os modelos de RNA que estão sendo sugeridos para a inspeção de qualidade da gasolina, por meio de uma revisão sistemática da literatura que compreende publicações disponíveis nas bases de dados Scopus, Biblioteca Digital do IEEE e *ScienceDirect*, dentro do período temporal de 2012-2022.

Além disso, o estudo visa identificar as técnicas que estão sendo sugeridas como forma de controle da qualidade da gasolina por meio da utilização de Redes Neurais Artificiais (RNAs) existentes, expondo as modificações sugeridas na estrutura destes modelos para alcançar maior desempenho e precisão dos resultados, e também, descrever o diferencial que esta alternativa auxilia na predição dos compostos da gasolina, discorrendo em torno da questão: Sob a perspectiva das RNAs, quais modelos e técnicas de controle de qualidade da gasolina estão sendo utilizadas na atualidade?



## **2 OBJETIVOS**

### **2.1 Objetivo geral**

Analisar os métodos de RNA por meio de uma revisão sistemática da literatura que estão sendo utilizados nos últimos 10 anos (2012-2022) como alternativa para a inspeção de qualidade da gasolina.

### **2.2 Objetivos específicos**

- Demonstrar por meio dos artigos selecionados para a pesquisa, como as RNAs podem ser utilizadas para a análise de qualidade da gasolina.
- Pesquisar e descrever os modelos de RNAs sugeridos no controle da qualidade da gasolina.
- Categorizar as publicações científicas selecionadas, como forma de diferenciar as pesquisas selecionadas.
- Expor aprimoramentos e modelagens realizadas nas RNAs utilizadas para obter um melhor desempenho dos modelos.

### 3 DESENVOLVIMENTO

Neste capítulo serão apresentados o conceito de gasolina, os compostos que fazem parte da sua estrutura química, os tipos de gasolinas produzidas no Brasil, as definições sobre octanagem *Research Octane Number* (RON) e *Motor Octane Number* (MON) e o contexto histórico que determinou a medida sobre o teor de Álcool Etilíco Anidro Combustível (AEAC) na gasolina. Também são apresentadas as leis que compõe a Legislação Brasileira referentes as características de cada tipo de gasolina comercializada, fatores que caracterizam a adulteração da gasolina, os métodos de análise da qualidade adotados pela Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP) para inspeção, bem como as causas e consequências que o uso da mistura adulterada pode causar ao veículo. Ao final do capítulo é abordado a definição de Redes neurais artificiais e as RNAs encontradas nos trabalhos utilizados nessa revisão sistemática.

#### 3.1 Gasolina

A gasolina é um produto líquido, inflamável e de alta volatilidade adquirido a partir do processo de refinamento e craqueamento do petróleo, representada pela fórmula química do iso-octano ( $C_8H_{18}$ ) (RODRIGUES, 2017). Por ser um produto de fundamental importância para o funcionamento de motores a combustão, é o segundo combustível mais consumido no Brasil (CARVALHO, 2014).

Levando em consideração a composição química da gasolina, esta, caracteriza-se por possuir mais de 400 compostos distintos, formados na maior parte por hidrocarbonetos e em sua minoria por compostos oxigenados, além de uma pequena concentração de contaminantes tóxicos (PASADAKIS, 2006).

Em vista da alta demanda para este tipo de combustível, existem leis que determinam as propriedades físico-químicas que o produto comercializado deve ter para ser fornecido ao consumidor final. Com isso, a ANP tem o objetivo de verificar a qualidade dos combustíveis comercializados no país, através das resoluções que decretam as características desejáveis para os tipos de combustíveis disponíveis no Brasil (ARAÚJO, 2013).

Os tipos de gasolinas definidos e especificados pela ANP são a gasolina do

tipo A e gasolina do tipo C. Apesar da permissão referente a importação, elas também são produzidas no país, na refinaria da Petrobrás a qual possui referência mundial na produção e classificação de gasolinas (MENDES, 2018).

### 3.1.1 Composição química

Os compostos da gasolina pertencem basicamente as classes das parafinas, olefinas, naftenos e aromáticos, com uma baixa composição de oxigenados constituídos por moléculas de 4 a 12 átomos de carbono. Além destes, pequenas concentrações de compostos tóxicos naturais (enxofre, oxigênio, benzeno, metais e nitrogênio) estão presentes na mistura (CARVALHO, 2014).

Em relação aos hidrocarbonetos presentes na gasolina, eles podem ser divididos nas seguintes classes:

- Parafinas: constituídas de hidrocarbonetos saturados, cicloparafinas ou naftênicos.
- Olefinas: representados por hidrocarbonetos com ligação dupla entre os carbonos. Sendo que, na presença de oxigênio, luz ou calor, esta classe geralmente reage com outros compostos ou até com pertencentes da mesma classe gerando polímeros.
- Aromáticos: apresentam o anel benzênico na estrutura, e fornecem uma resistência a detonação para gasolina. Em vista, que também está relacionado a geração da fumaça e depósitos de carbono durante o processo de combustão do motor (TAKESHITA, 2006).

### 3.1.2 Tipos de gasolina

Como expresso anteriormente, a gasolina pode ser dividida em gasolina tipo A e gasolina tipo C, porém de acordo com a ANP, as refinarias são responsáveis apenas pela produção de gasolina do tipo A e suas subdivisões, e as companhias distribuidoras por sua vez realizam a adição de AEAC dentro das especificações estabelecidas pela ANP afim de obter a gasolina comercializada tipo C (BRASIL, 2020a). Com isso, as subdivisões dos tipos de gasolinas no Brasil são:

- Gasolina Tipo A: é o produto base da Gasolina Tipo C disponível nas revendedoras, isenta de AEAC, porém a ANP ressalta que este tipo de produto não

deve ser comercializado em postos de combustíveis (AMARAL, 2019).

- Gasolina Tipo C Comum: apresenta MON mínimo de 82 e índice antidetonante (IAD) mínimo de 87, fornecido legalmente ao consumidor pelas revendedoras de combustível. Sendo o resultado da mistura da gasolina tipo A com AEAC, apresenta coloração amarela e não possui aditivos ou corantes (DAGOSTIN, 2003).

- Gasolina Tipo C Aditivada: também obtida da mistura da gasolina tipo A com AEAC, com mesmas restrições quanto a octanagem, sendo legalmente fornecida ao consumidor pelas revendedoras. Porém esta recebe um corante (verde ou vermelho) com intuito de diferenciá-la, além de possuir adição de aditivos do tipo “detergente dispersante”, que são responsáveis pela limpeza do sistema de alimentação do motor (PETROBRAS, 2020).

- Gasolina Premium: não apresenta diferença nos níveis de desempenho do motor, nem acréscimo no valor da octanagem, porém têm melhorias em relação a centralização do processo de combustão e valor elevado de IAD, que é correspondente a 91, possuindo menor teor de enxofre (até 50 ppm) e fatores que auxiliam a redução da emissão de gases poluentes, segundo a Resolução ANP nº 807, de 23 de janeiro de 2020 (BRASIL, 2020b).

### 3.1.3 Octanagem

A octanagem representa a resistência fornecida pela gasolina à detonação do motor, sendo necessário seguir os padrões impostos pela ANP para evitar ruídos incomuns no motor, que podem danificá-lo (PETROBRAS, 2020).

A octanagem pode ser calculada pela razão entre a resistência de explosão real da gasolina pela resistência à explosão da gasolina padronizada (WANG *et al.*, 2020).

No processo de avaliação do número de octanas da gasolina são inspecionados os valores de MON e RON (DAGOSTIN, 2003):

- *Motor Octane Number* (MON): representa a resistência da gasolina à detonação, em casos que o motor atinge valores altos de rotação, geralmente ocasionado pelo aumento do torque do motor.

- *Research Octane Number* (RON): é a resistência da gasolina à detonação, em casos que o motor está em uma rotação menor e apresenta baixa queima de combustível.

Em vista que a gasolina possui vários critérios de análise, além de um número alto de compostos já mencionados anteriormente, a octanagem refere-se a um dos indicadores mais importantes e relevantes na análise da qualidade da gasolina (WU *et al.*, 2022)

#### 3.1.4 Teor Alcólico da Gasolina: contexto histórico

A adição de etanol na gasolina é vantajosa por fornecer mais propriedades de IAD a esta mistura, baixo teor de compostos tóxicos e apresentar redução na emissão de monóxido de carbono na atmosfera. Porém, em casos de vazamento, pode contaminar águas subterrâneas devido à alta solubilidade dos hidrocarbonetos monoaromáticos presentes na mistura (TAKESHITA, 2006).

Considerando as vantagens apresentadas pelo uso do AEAC, a obrigatoriedade da adição de etanol na gasolina passou a ser válida após a criação do Instituto do Açúcar e do Alcool (IAA) em 1933, pelo governo de Getúlio Vargas. Porém, só foi decretada como lei em 23 de setembro de 1938, decreto nº 737, de 1938 (BRASIL, 1938a).

Esta lei ainda está em vigor no país, sendo aplicada a toda gasolina automotiva comercializada no Brasil pelas revendedoras autorizadas pela ANP. A porcentagem volumétrica é determinada pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA), estabelecida atualmente entre 18% e 27,5% de acordo com Lei nº 13.033/2014 (BRASIL, 2014).

#### 3.1.5 Legislação

A Resolução ANP nº 807, de 23 de janeiro de 2020, considera 21 especificações para análise da gasolina antes da comercialização. Estas referem-se a várias normas referentes a qualidade, que vão desde as características de sua coloração, até a verificação de possíveis adulterações (BRASIL, 2020b).

Nesse sentido, a legislação brasileira estabelece também que todos os tipos de gasolina comercializada devem receber adição de etanol anidro com um percentual de 27% com margem de erro à 1%, não sendo permitida um teor abaixo de 20%.

Nessa porcentagem, a adição de etanol anidro à gasolina ajuda na diminuição de poluentes, como o monóxido de carbono, além de melhorar a limpeza interna do motor (BRASIL, 2020b).

Segundo a ANP, um dos fatores relevantes na análise da gasolina, são os dados referentes a octanagem e IAD, que determinam as propriedades físico-químicas do combustível e devem estar dentro das especificações determinadas para cada tipo de gasolina, como já foram mencionadas com maiores detalhes no tópico que diz respeito aos tipos de gasolina. Além da determinação do RON, a Resolução ANP nº 807, de 23 de janeiro de 2020, estabelece que a gasolina regulamentada tem massa específica a 20°C para todos os tipos e destilação em 50% evaporados para gasolina comum e *premium A* (BRASIL, 2020b).

### 3.1.6 Adulteração da gasolina

A prática de adulteração é causada pela adição de qualquer produto inserido na gasolina que altere suas características originais e afetam a mistura (PETROBRAS, 2020).

Nas últimas décadas, a prática de adulteração em combustíveis tem gerado preocupação nos órgãos fiscalizadores e tem levado a ANP a impor medidas para coibir essa ação ilícita nos postos de combustíveis em todo o país. Por meio de uma Resolução do Conselho Interministerial do Açúcar e do Alcool (CIMA) de 4 de março de 2015, foi estabelecido como aceitável um teor de etanol em gasolina de no máximo 27% em volume, conforme disposto no Art. 1º, da Lei 10.203/2001 (ANP, 2017).

De acordo com Takeshita (2006) os principais fatores que mais contribuem para as práticas ilegais de adulteração são a diferença entre os custos do solvente e da gasolina, a facilidade na aquisição dos solventes, a dificuldade de detecção visual dos solventes quando misturados à gasolina e os altos impostos aplicados na gasolina comercializada, que diminui o lucro sobre a venda do produto.

Prudente (2010) elucida que as consequências que a adulteração da gasolina pode provocar ao veículo são muitas, as quais destacam-se o aumento no consumo e perda de potência, corrosão e desgaste dos motores e equipamentos, carbonização das velas, batida de pino (ruídos metálicos com aumento na temperatura do motor) e diminuição do rendimento.

Outra questão importante é o fator ambiental. O uso de gasolina adulterada também causa impactos ambientais, uma vez que aumenta a produção de poluentes como óxidos de nitrogênio (NOx) e óxidos de enxofre (SOx), bem como monóxido de carbono (CO), o qual está vinculado com o desencadeamento de patologias respiratórias que afetam o ser humano (NASCIMENTO *et al.*, 2020).

As mudanças nas características da gasolina podem ser provocadas pelo acréscimo de substâncias com composições diferentes das que a gasolina já possui, ou pelo excesso de compostos químicos presentes na mistura (TAKESHITA, 2006).

A gasolina pode ser adulterada pela adição de solventes como óleo diesel, querosene, refinados petroquímicos, solventes de borracha e acréscimo de AEAC acima do limite permitido pela ANP. Com intuito de impedir estas infrações, a ANP realiza testes de qualidade frequentemente dos combustíveis distribuídos no Brasil, investigando se as revendas estão cumprindo as especificações exigidas para gasolina (COSTA, 2021).

A adulteração da gasolina interfere de maneira diferente, de acordo com o tipo de solvente adicionado ou acréscimo de AEAC:

- Adição de óleo diesel: pode provocar a carbonização da câmara de combustão (PINTO, 2012).
- Adição de querosene: causa falhas na aceleração, carbonização da câmara de combustão e detonação em baixas rotações (OLIVEIRA, 2018).
- Adição de refinados petroquímicos: tornam a gasolina imprópria para o consumo, por possuir um teor de aromáticos baixo, logo uma baixa octanagem, além disso o método cromatográfico determinado pela ANP não identifica a adulteração referente a estas substâncias (NASCIMENTO, 2008).
- Adição de solventes de borracha: pode danificar diafragmas e mangueiras, além da diminuição da octanagem que aumenta a tendência à detonação (PINTO, 2012).
- Adição de AEAC: acima do limite estabelecido pela ANP ocasiona problemas como falhas no funcionamento e perda de desempenho do motor, além da redução da energia interna gerada pela gasolina (PINTO, 2012).

A gasolina tem compostos semelhantes aos solventes adulterantes, o que torna difícil a verificação destes quando estão em níveis inferiores a 30%. Por outro lado, o excesso de AEAC é possível detectar de forma facilitada por testes simples como o teste da proveta (PRUDENTE, 2010).

Em vista dos problemas que a adulteração da gasolina pode causar, faz-se necessário o uso de medidas referentes ao emprego de técnicas analíticas que possam identificar de forma rápida e precisa este tipo de alteração nas propriedades do combustível. Com isso a ANP adota a espectroscopia e a cromatografia como ferramentas para verificação da qualidade dos combustíveis (OLIVEIRA, 2018).

Em casos que a gasolina é adulterada, de acordo com o artigo 1º, inciso I, da lei 8.176/91 constitui-se crime contra a ordem econômica adquirir, distribuir e revender derivados de petróleo, gás natural e suas frações recuperáveis, álcool etílico, hidratado carburante e demais combustíveis líquidos carburantes, em desacordo com as normas estabelecidas na lei. Condenando o infringente a uma pena de detenção por 1 a 5 anos (BRASIL, 1991).

O Brasil possui um número elevado de postos de gasolina, que torna difícil a fiscalização de modo generalizado pelos métodos atuais utilizados pela ANP, com isso as adulterações continuam a acontecer (TAKESHITA, 2006). Diante disso, sugere-se que o condutor exija sempre nota fiscal após o abastecimento do veículo, para verificar se a origem dos produtos está regulamentada. É importante ressaltar que os postos de combustíveis, de acordo o artigo 8º da Portaria 248/2000 da ANP tem a obrigação de realizar o teste da proveta em casos que o consumidor solicitar ou tiver dúvidas referentes a procedência do combustível (PRUDENTE, 2010).

### **3.2 Redes Neurais**

Em vista do campo amplo que as RNAs podem ser utilizadas na resolução de problemas lineares ou não lineares, e pelo fato delas auxiliarem em diversas aplicações de problemas matemáticos e previsões de dados, a proposta deste capítulo será apresentar a definição sobre as RNAs, demonstrar o conceito e a importância desse meio alternativo no controle de qualidade da gasolina, e esclarecer os principais componentes da RNA que irão abranger desde a arquitetura padrão até os tipos de conexões (sinapses) que interligam as camadas.

Ainda referente ao uso das RNAs, serão analisadas as vantagens e desvantagens, a maneira que os modelos podem ser usados no controle da qualidade da gasolina, detalhando sobre as funções e estrutura das RNAs que apareceram nas pesquisas selecionadas para este trabalho. E por fim, serão detalhadas as redes



neurais *Backpropagation* (RNA BP) e Rede Neural de Função de Base Radial (RBF) que apareceram nesta pesquisa de revisão como sendo as principais alternativas no controle de qualidade da gasolina.

### 3.2.1 Definição

As primeiras noções sobre RNAs começaram a surgir em 1943 com o trabalho de McCulloch e Pitts, que buscava um modelo computacional que simulasse o cérebro humano. Entre as décadas de 50 e 60, o entusiasmo pelas pesquisas neste campo cresceu com a proposta de um método inovador de aprendizagem para as RNAs denominado “perceptron” que foi apresentado por Rosenblatt. Anos mais tarde, em 1969, Minsky e Pappert publicaram um livro expondo as limitações do perceptron, que fez com que as pesquisas diminuíssem nos anos seguintes, voltando a reaparecer nos anos de 80 com avanços nos recursos computacionais e nas técnicas usadas (FERNEDA, 2006).

As RNAs podem ser descritas como modelos computacionais que se assemelham a um conjunto de neurônios artificiais, modelados matematicamente e possuem capacidade computacional adquirida por meio de aprendizado e generalização (BRAGA, 2007). Haykin (2001, p. 28) aponta que:

[...] uma rede neural é uma máquina que é projetada para modelar a maneira como o cérebro realiza uma tarefa particular [...]; a rede é normalmente implementada utilizando-se componentes eletrônicos ou é simulada por programação.

Neste sentido, a RNA é capaz de executar uma tarefa sem que o procedimento seja previamente programado, ou seja, possuem um aprendizado que possibilita a execução de determinado conjunto de dados com excelente precisão dos resultados. Estes fatores permitem a aplicação dos modelos em diversos tipos de problemas de classificação, agrupamento de dados ou otimização (MAKIUCHI, 2018).

Embora o nível de complexidade das RNAs seja menor que o cérebro humano que serviu de inspiração, seu aprendizado permite realizar análise para diferentes problemas. Por este motivo, são usadas em tarefas como reconhecimento de padrões, processamento de sinais, além da identificação de sistemas e controle (FLECK *et al.*, 2016).

Na estrutura da RNA, os dados são processados pelos neurônios do modelo e podem ser compostos por sistema linear ou não linear. Apesar de escolhas que se referem a equações matemáticas, a correlação entre as variáveis de saída e de entrada são determinadas conforme o treinamento (FLECK *et al.*, 2016; LI *et al.*, 2017; ABDELKHALEK *et al.*, 2019).

Além disso, por ser capaz de aliar baixo custo, tempo de análise e minimizar erros operacionais, são ferramentas úteis e eficazes, tornando-se uma forma alternativa e muito importante no controle de qualidade da gasolina (AGUIAR *et al.*, 2009).


### 3.2.2 Arquitetura da RNA

A forma como os neurônios estão ordenados na camada define a arquitetura da RNA, sendo que, não possui limitações para os números de neurônios que são inseridos no modelo. Além disto, conforme o problema proposto, permite a utilização de uma ou mais camadas intermediárias (ocultas) entre a camada de entrada e de saída. Com isso, elas são divididas em três partes principais (SILVA *et al.*, 2010):

- Camada de Entrada: é a camada de alimentação da RNA, ou seja, os dados propostos pelo problema são inseridos para dar início a previsão dos resultados.
- Camadas Ocultas: conhecida como camada intermediária, é onde ocorre a maior parte do processamento, e dependendo o modelo de RNA pode conter uma ou várias camadas compostas por neurônios que tem objetivo de calcular os dados requeridos.
- Camada de Saída: recebe os dados da camada oculta e apresenta os resultados para o problema proposto inicialmente.

A Figura 1, a seguir, demonstra a posições destas camadas compostas pelos neurônios:

**Figura 1: Representação simplificada de uma rede neural artificial**



Fonte: Ferneda (2006 p. 26)


As RNAs podem ser compostas por dois tipos de conexões (Carvalho, 1998):

- *Feedforward*: a saída de um neurônio na  $i$ -ésima camada da rede não pode ser usada como entrada de nodos em camadas de índice menor ou igual a  $i$ . Descreve modelos não lineares, úteis no reconhecimento e classificação de padrões e pode ser vista como ferramenta para análise de regressão não linear.

- *Backward*: a saída de algum neurônio na  $i$ -ésima camada da rede é usada como entrada de nodos em camadas de índice menor ou igual a  $i$ . São usadas na recuperação de um padrão de entrada.


Abaixo ilustram-se as Figuras 2 e 3, que demonstram estes tipos de conexões:

**Figura 2: RNA *feedforward* ou acíclica**



Fonte: Carvalho (1998 p. 7)

**Figura 3: RNA *feedback* ou cíclica**



**Fonte: Carvalho (1998 p. 7)**

Ainda sob a perspectiva dos componentes da RNA, elas possuem funções de ativação que, de acordo com Braga *et al.* (2007), são responsáveis por restringir a amplitude do valor de saída de um neurônio.

A seguir estão as principais funções de ativação que são elementos extremamente importantes, pois decidem quando um neurônio deve ser ou não ser ativado (NIELSEN, 2014):

- Função de ativação linear: usada em processos de regressão numérica, geralmente na camada de saída. Apresenta forma gráfica crescente e os valores são definidos no intervalo de 0 a 1 (CARVALHO, 2018).
- Função linear (PURELIN): auxilia no treinamento orientando a adequação dos pesos sinápticos conforme o erro apresentado. Tem valores de saída de 0 e 1, sendo geralmente empregada em camadas que possuam números positivos em sua saída (REIS, 2016).
- Função de ativação sigmoide: é uma função contínua e diferenciável em todos os pontos, não linear que essencialmente empurra os valores de Y para os extremos na tentativa de classificar os valores (NIELSEN, 2014).
- Função de ativação sigmoide (TANSIG): é uma função escalonada da função sigmoide, contínua e diferenciável em todos os pontos que permite solucionar problemas nos dados contanto que estejam todos com mesmo sinal (NIELSEN, 2014).
- Função de ativação ReLU (*Rectified Linear Units*): É uma função não linear, que

permite ter várias camadas de neurônios ativadas pela função. Sua principal vantagem sobre as outras é que ela não ativa todos neurônios ao mesmo tempo, o que torna a rede mais eficiente e fácil para computação. Porém, apresenta problemas com gradientes que se deslocam em direção a zero (NIELSEN, 2014).

- Função de ativação *Exponential Linear Unit* (ELU): é uma função de ativação que permite empurrar as ativações da unidade média o mais próximo de zero, além de diminuir a variação e informações propagadas, possibilitando acelerar o aprendizado da RNA e diminuir o erro de classificação (CLEVERT, 2016).

### 3.2.3 Vantagens e desvantagens do uso de RNA

Uma RNA que o treinamento apresenta desempenhos satisfatórios, permite realizar previsões por meio de testes com diferentes dados inseridos na entrada da estrutura (LOPES, *et al.* 2009). Por influência dos benefícios que a RNA pode oferecer, abaixo será apresentado uma lista referente as vantagens e desvantagens da utilização de RNAs, na resolução de problemas e previsão de dados. Inicialmente, as principais vantagens do uso destes modelos são (REIS, 2021):

- Flexibilidade: Possibilita constituir não linearidades presentes nas relações entre variáveis de resposta e as covariáveis, que proporciona uma previsão sofisticada.
- Adaptabilidade: Não possui necessidade de alteração da estrutura, após a construção de uma rede que apresente boa precisão para determinada aplicação, basta apenas realizar um novo treinamento com os novos dados do problema proposto.
- Capacidade de generalização: consegue preencher lacunas sem sofrer degradação, mesmo em casos que os dados fornecidos são incompletos ou imprecisos;

Em contrapartida, o uso das RNAs possui desvantagens como (FLECK *et al.*, 2016):

- Tempo de treinamento: dependendo da aplicação do problema proposto, o treinamento pode demorar algumas horas ou dias;
- Volume excessivo de dados: demanda de um número relativamente alto de dados de treinamento adequado;
- Preparação dos dados: todos dados de entrada precisam passar por tratamento

prévio, ou seja, uma seleção para a RNA ser treinada de forma apropriada.

Diante das desvantagens apresentadas acima, pesquisas promissoras geralmente propõe melhorias para solucionar ou amenizar estas desvantagens (LOPES *et al.*, 2009).

#### 3.2.4 Aprendizado das RNAs

Os modelos de RNAs utilizam principalmente dois tipos de algoritmos de aprendizado, que são o aprendizado supervisionado e o aprendizado não-supervisionado (SILVA, 2014):

- Aprendizado supervisionado: é a previsão de uma variável dependente por meio de várias variáveis independentes, ou seja, um supervisor externo fornece à RNA a saída desejada em relação a um padrão de entrada, sendo possível obter resultados de saídas em função das variáveis de entrada. A partir das respostas obtidas, são efetuados ajustes nos pesos sinápticos de maneira que diminua o erro calculado entre os valores de saída (FLECK *et al.*, 2016). O *Backpropagation* é o algoritmo mais utilizado nesta forma de aprendizado (HAYKIN, 2001).

- Aprendizado não supervisionado: a RNA determina o valor da resposta por meio do sinal de entrada inserido a partir dos dados pré-estabelecidos (HAYKIN, 2001). Segundo Simões (2006), o aprendizado não supervisionado ocorre em casos que não há categorização ou rotulação dos dados, assim a rede os determina sem o conhecimento da resposta desejada, ou seja, apenas com informações do número de classes requeridas e topologia. Com isso, o objetivo deste aprendizado é fazer com que cada neurônio armazene o centro de um grupo e dispare o neurônio da saída. Neste aprendizado não existe um supervisor acompanhando o processo de aprendizagem, e a RNA precisa procurar algum tipo de correlação ou redundância nos dados de entrada (FLECK *et al.*, 2016).

#### 3.2.5 RNAs utilizadas na análise de qualidade da gasolina

As RNAs vêm ganhando atenção porque foram implementadas com sucesso como ferramentas de modelagem e otimização na resolução de problemas complexos

e não lineares (ELFGHI *et al.*, 2016). Além disso, Bassam *et al.* (2014) destacam que as RNAs estão sendo utilizadas cada vez mais como fonte para resolução de problemas. Neste contexto, uma área da engenharia que tem sido aplicada as redes neurais é na indústria petroquímica em questões de otimização da eficiência energética para determinada planta petroquímica, classificação da gasolina *premium* e gasolina comum por cromatografia gasosa, desempenho e emissões de escape de um motor a gasolina, previsão de torque e consumo específico de combustível de um motor a gasolina, determinação do índice de octanas de compostos de gasolina a partir de sua estrutura química, entre outras diversas aplicações.

Segundo Abdul *et al.* (2018), esta alternativa vem atraindo interesse na previsão de fenômenos químicos complexos, como prever a octanagem (RON e MON) por meio de compostos inseridos na gasolina (hidrocarbonetos puros, misturas de hidrocarboneto-etanol). Em vista disso, Tao *et al.* (2022) menciona que modelos de RNA como RNA BP podem contribuir com tarefas de previsão da octanagem da gasolina caso forem feitos alguns ajustes no modelo para minimizar o erro e aumentar seu desempenho.

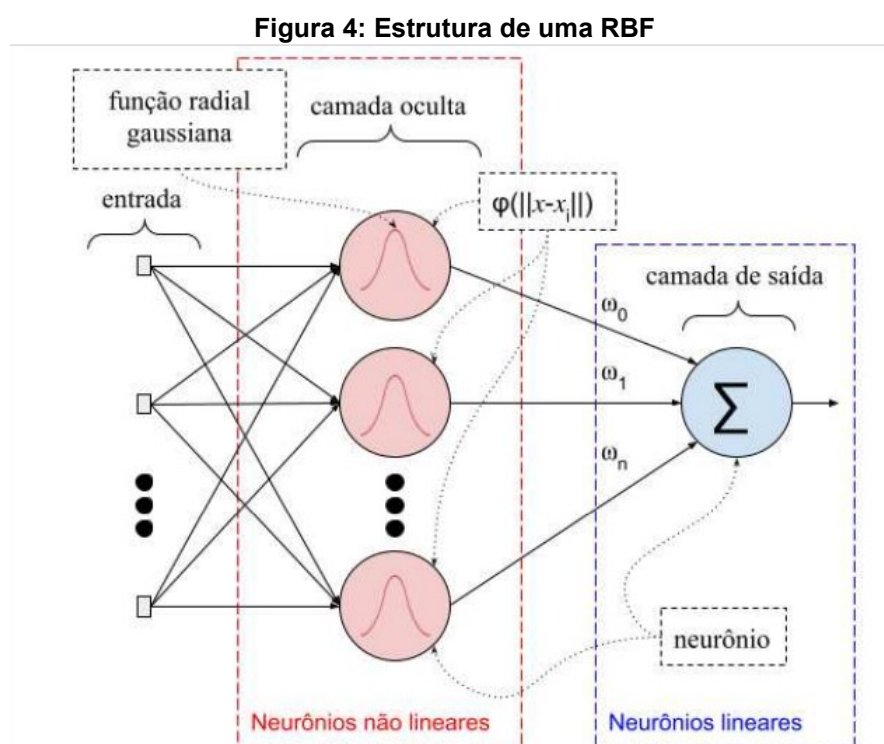
### 3.2.6 Rede Neural de Função de Base Radial (RBF)

Criada por Broomhead e Lowe (1988), a RBF apresenta uma estrutura fixa com uma única camada oculta, com neurônios lineares e uma função de ativação de base radial (VON ZUBEN; ATTUX, 2001).

A estrutura deste modelo geralmente conta com uma função de ativação gaussiana, sendo constituída por três camadas com finalidades distintas (LIMA; GUERREIRO, 2011):

- Camada de entrada: as unidades sensoriais (neurônios de entrada) são conectadas com ambiente externo e são responsáveis para transmitir estes dados à camada oculta;
- Camada oculta: recebe os dados da camada de entrada, e aplica uma transformação não-linear;
- Camada de saída: tem forma linear e irá fornecer a resposta do aprendizado determinado na camada de entrada.

Um fator relevante na representação da RBF, distinta das Redes Neurais *Multi Layer Perceptron* (MLP), é que ela não possui pesos sinápticos (valores atribuídos as conexões) entre a camada de entrada e camada oculta da RNA que é uma característica da sua estrutura não linear. Abaixo, a Figura 4 ilustra a estrutura da RBF (SAGAZ, 2021):



Fonte: SAGAZ (2021 p. 28)

Este modelo realiza aprendizado supervisionado, e tem função de encontrar uma superfície em espaço multidimensional que forneça o melhor ajuste de dados, possibilitando aproximar qualquer função através da combinação linear de funções gaussianas com centros em pontos distintos escolhidos aleatoriamente na entrada da RNA (SILVA, 2016).

### 3.2.7 Rede Neural *Backpropagation* (RNA BP)

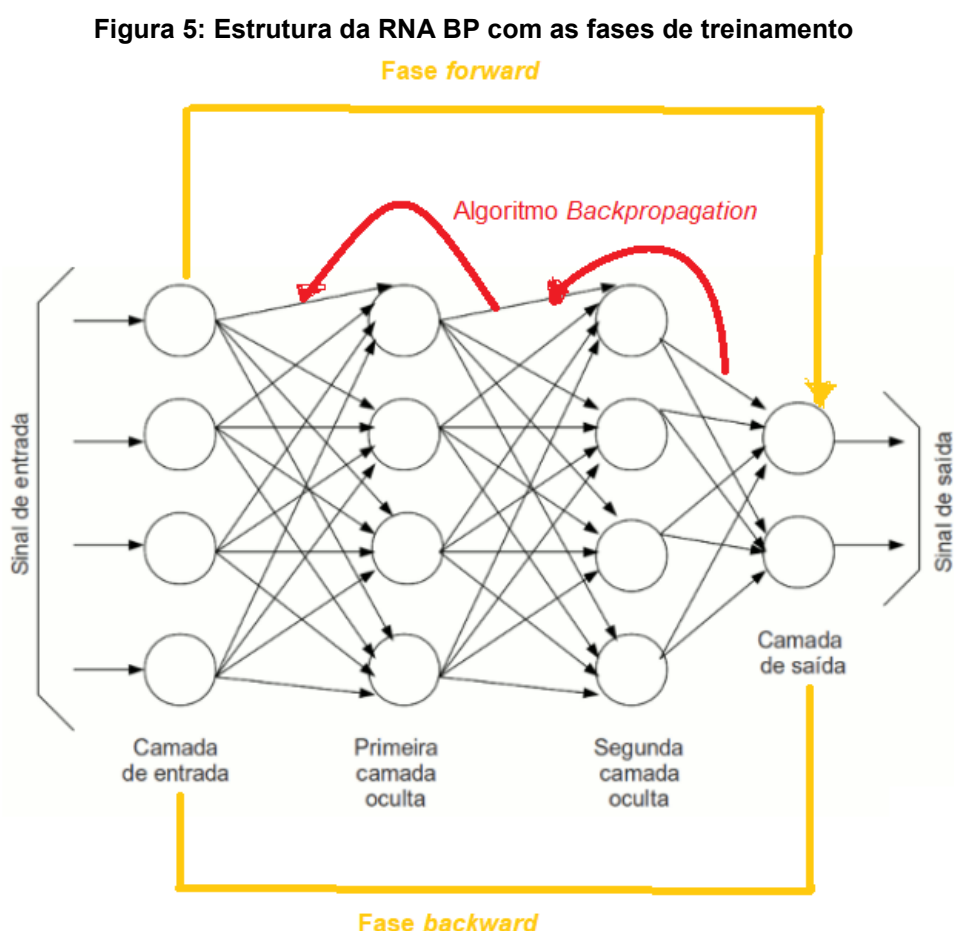
Proposta por Rinehart no ano de 1986, é uma rede do tipo *feedforward* que tem capacidade de mapeamento não linear, autoaprendizagem e auto adaptação, generalização e tolerância a falhas. Esta rede permite a utilização de algoritmos para



auxílio na precisão dos resultados, sendo geralmente treinada por propagação de erro (WANG *et al.* 2020).

A RNA BP normalmente envolve camada de entrada, duas ou mais camadas ocultas e camada de saída, todas compostas por um número determinado de nós nas três camadas. Neste tipo de RNA, a função de transferência é inserida na camada oculta que apresenta número de nós de acordo com a minimização de erros para determinada pesquisa (FENG, *et al.* 2021). Além disso, utiliza a retropropagação de erro entre os valores previstos e reais para atualizar os dados da sua estrutura (CUI, *et al.*, 2022).

Neste modelo, existem duas fases para o treinamento de uma RNA, a fase *forward* e a fase *backward*. A fase *forward* define a saída da rede com determinado padrão de entrada, por outro lado a fase *backward* usa a saída selecionada e a saída fornecida pela RNA para atualizar os pesos sinápticos de suas conexões. Abaixo, a Figura 5 representa a estrutura da RNA BP e ambas as fases (MORAIS, 2010):



Fonte: Adaptada de SILVA (2019)

De acordo com Tao *et al.* (2022) este modelo é tradicionalmente utilizado na previsão de octanagem, porém tem necessidade de recursos de otimização com base em algoritmos para sobrepor problemas de baixa precisão e má generalização do modelo padrão de RNA BP.

## 4 PROCEDIMENTOS METODOLÓGICOS

A revisão sistemática consiste em um tipo de revisão que propõe responder uma questão de pesquisa de forma objetiva e imparcial. Para isso ela precisa ser conduzida com base em um protocolo, que é o princípio da pesquisa e será utilizada no decorrer do trabalho (BIOLCHINI *et al.*, 2005; KITCHENHAM, 2004).

Sendo assim, nesta pesquisa o protocolo previamente definido para condução da revisão foi baseado no modelo de Nunes (2015), que abrange as questões de pesquisa, as quais são respondidas e discutidas nos resultados, seleção de fontes, *keywords* e construção de *strings*, além dos critérios de análise de inclusão e exclusão de artigos para o estudo, bem como, a verificação do SNIP do artigo.

O SNIP trata-se de um número médio de citações de itens publicados recentemente no periódico contextualizado por área do conhecimento. Este número é o resultado da razão entre o número médio de citações por artigo e o potencial de citação da área do conhecimento a que se refere o periódico.

### 4.1 Questões de pesquisa

Três questões de pesquisas foram elaboradas com intuito de alcançar o objetivo da pesquisa e conduzir a organização dos artigos previamente selecionados:

As redes neurais artificiais estão sendo utilizadas para o controle de qualidade da gasolina?

Quais são as redes neurais artificiais existentes para avaliar a qualidade da gasolina?

Quais RNAs são mais utilizados para inspeção da gasolina? Por que?

### 4.2 Seleção de fontes

A seleção das fontes foi definida levando em consideração as bases de dados referências no âmbito científico, bem como, considerando a temática proposta. Encontra-se abaixo as três bases de dados utilizadas:

SCOPUS (<http://www.scopus.com/home.url>)

Biblioteca Digital do Instituto de Engenheiros Eletricistas e Eletrônicos (IEEE)  
(<http://ieeexplore.ieee.org/Xplore/>)

*ScienceDirect* (<https://www.sciencedirect.com/>)

### 4.3 Palavras-chave

As *keywords* (do português: palavras-chaves), foram utilizadas selecionando o produto de análise – gasolina, e o método de análise que a pesquisa propõe – *neural network* (do português: rede neural) que foram fixas na construção de todas *strings* constituídas, no entanto, uma mudança ocorreu apenas na última *keyword*, para remeter aos principais parâmetros mais influentes na qualidade da gasolina, que são: *octane number prediction* (do português: previsão do número de octanas), *antiknock performance* (do português: performance antidetonante) e *density* (do português: densidade). Sendo assim, as seguintes *strings* de busca utilizadas para pesquisa nas bases de dados citadas anteriormente foram:

Analytical Models

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":octane number prediction): 2012-2022 - IEEE

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":antiknock performance): 2012-2022 – IEEE

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":density): 2012-2022 – IEEE

gasoline AND "neural network" AND "octane number prediction": 2012-2022 – ScienceDirect

gasoline AND "neural network" AND "antiknock performance": 2012-2022 – ScienceDirect

gasoline AND "neural network" AND "density": 2012-2022 – ScienceDirect

gasoline AND "neural network" AND "octane number prediction": 2012-2022 – Scopus

gasoline AND "neural network" AND "antiknock performace": 2012-2022 - Scopus

gasoline AND "neural network" AND "density": 2012-2022 – Scopus

#### **4.4 Tipo dos artigos**

Na seleção dos tipos de artigos científicos que foram estudados durante esta pesquisa de revisão sistemática da literatura, foram considerados apenas pesquisas relacionadas a área de RNAs aplicadas à qualidade da gasolina, com período de publicação entre os anos de 2012 a 2022.

#### **4.5 Idioma(s) dos artigos**

Inglês. Por ser uma língua “universal” e aceita na maioria das revistas científicas. Artigos na língua inglesa, além de serem publicados em maior quantidade, normalmente recebem mais citações do que os publicados em outros idiomas.

#### **4.6 Critérios de inclusão e exclusão dos trabalhos**

Os critérios de inclusão e exclusão foram definidos de modo a selecionar os artigos obtidos nos resultados das bases de dados e auxiliar na resolução das questões de pesquisa.

##### **4.6.1 Critérios de inclusão**

Os seguintes critérios de inclusão foram desenvolvidos para seleção dos artigos de estudo:

- (a) Textos completos, na língua inglesa com acesso livre e gratuito nas bases

de dados previamente citadas;

- (b) Incluídos trabalhos (publicados no período de 2012-2022) que possuam aprovação pela comunidade científica;
- (c) Foram exigidos trabalhos publicados em periódicos com SNIP maior ou igual a 0,5;
- (d) Utilizou-se trabalhos que abordaram sobre os métodos de análise da gasolina com RNAs;

#### **4.6.2 Critérios de exclusão**

Os seguintes critérios de exclusão foram criados para descarte dos artigos irrelevantes para o estudo:

- (e) Foram excluídos pôsteres e livros;
- (f) Excluídas pesquisas que apresentam avaliações sem apresentar o método utilizado;
- (g) Excluídos estudos que não atendam os objetivos do estudo proposto;
- (h) Foram excluídas pesquisas que não apresentam resultados consistentes da inspeção da gasolina;
- (i) Excluídas pesquisas que não utilizam RNA no processo de inspeção;
- (j) Excluídos artigos com SNIP menor que 0,5;
- (k) Foram excluídos artigos que não possuem acesso livre;
- (l) Foram excluídas pesquisas que não descrevem a estrutura da RNA utilizada.

#### **4.7 Critérios de qualidade dos estudos primários**

O trabalho exigiu artigos publicados em revistas com SNIP maior ou igual a 0,5. Além disso, serão considerados artigos científicos recentes (publicados no período de 2012-2022).

#### **4.8 Processo de seleção dos estudos primários**

Foram construídas *strings* com as palavras-chave e seus sinônimos, as quais foram submetidas às ferramentas de busca nas bases de dados escolhidas para

pesquisa, após isto, foi realizada a leitura do resumo e aplicação dos critérios de inclusão e exclusão. O trabalho foi selecionado de acordo com sua relevância, e descartado quando não era condizente ao objetivo da pesquisa. Em um cenário o qual houve dúvida em relação a relevância, o orientador foi consultado, e com a aprovação, o artigo foi selecionado para ser lido na íntegra e feito o destaque dos principais pontos da pesquisa.

#### **4.9 Estratégia de extração de informação**

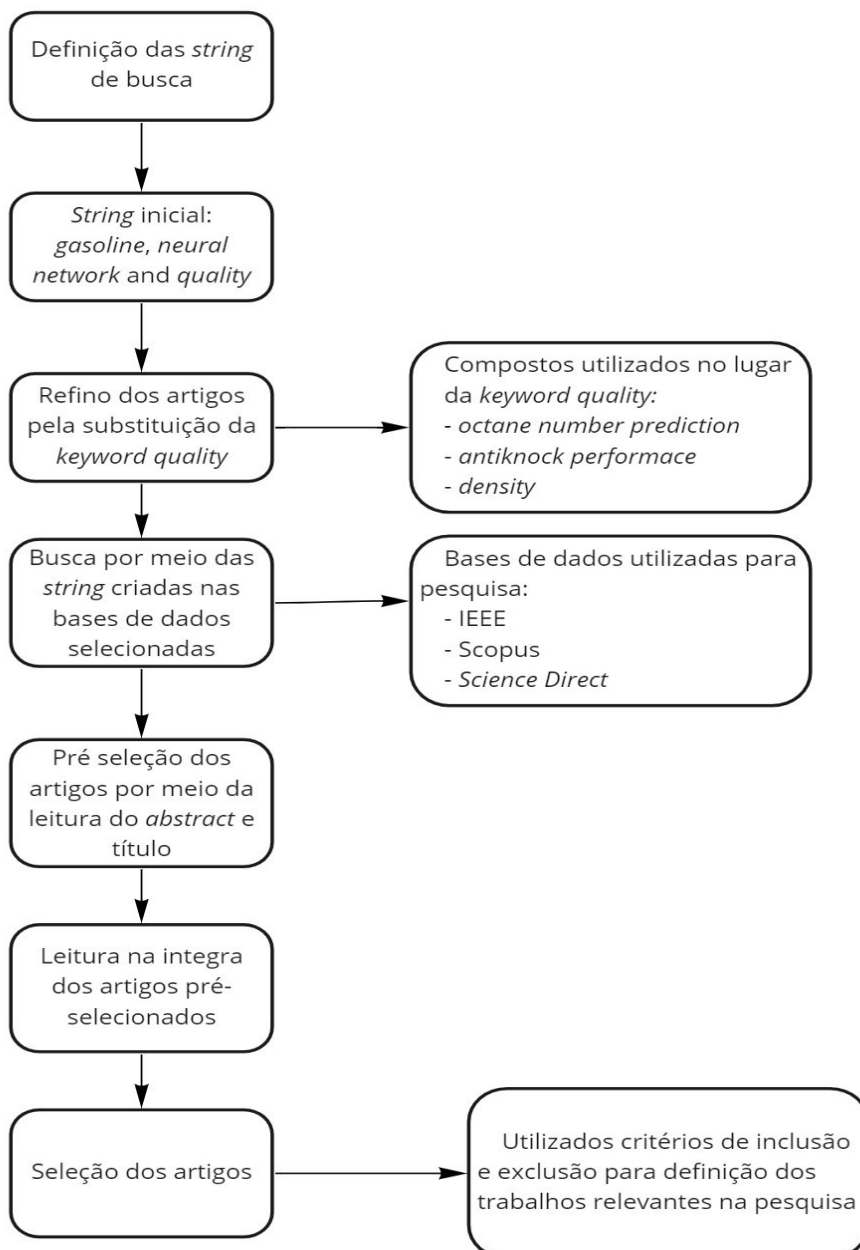
Com a leitura na íntegra dos artigos incluídos, o revisor destacou os pontos importantes de cada um dos artigos, distinguindo as RNAs utilizadas para avaliação e parâmetros considerados.

Em vista disso, foram preenchidos “formulários de extração de dados” para cada artigo. Além das informações básicas (dados bibliográficos, data de publicação, *abstract*, entre outros), estes formulários contêm a síntese do trabalho, redigida pelo pesquisador.

#### **4.10 Sumarização dos resultados**

Com a leitura na íntegra dos artigos selecionados, foi elaborado um relatório técnico com a análise quantitativa dos trabalhos e também a análise qualitativa a fim de definir as vantagens e desvantagens de cada RNA, com a extração das informações relevantes.

Diante disso, após a verificação de todos pontos de inclusão e exclusão, para cada artigo selecionado foram preenchidos formulários de coleta de informações, na qual as análises estão apresentadas nos resultados deste trabalho. Com isso, para uma melhor compreensão do procedimento, foi criado o Fluxograma 1, como demonstrado abaixo, que apresenta de forma sucinta como foi desenvolvida a busca e a seleção dos artigos, visando a metodologia proposta para pesquisa.

**Fluxograma 1: Procedimento da extração e seleção dos artigos**

Fonte: Autoria própria (2022)



## 5 RESULTADOS E DISCUSSÃO

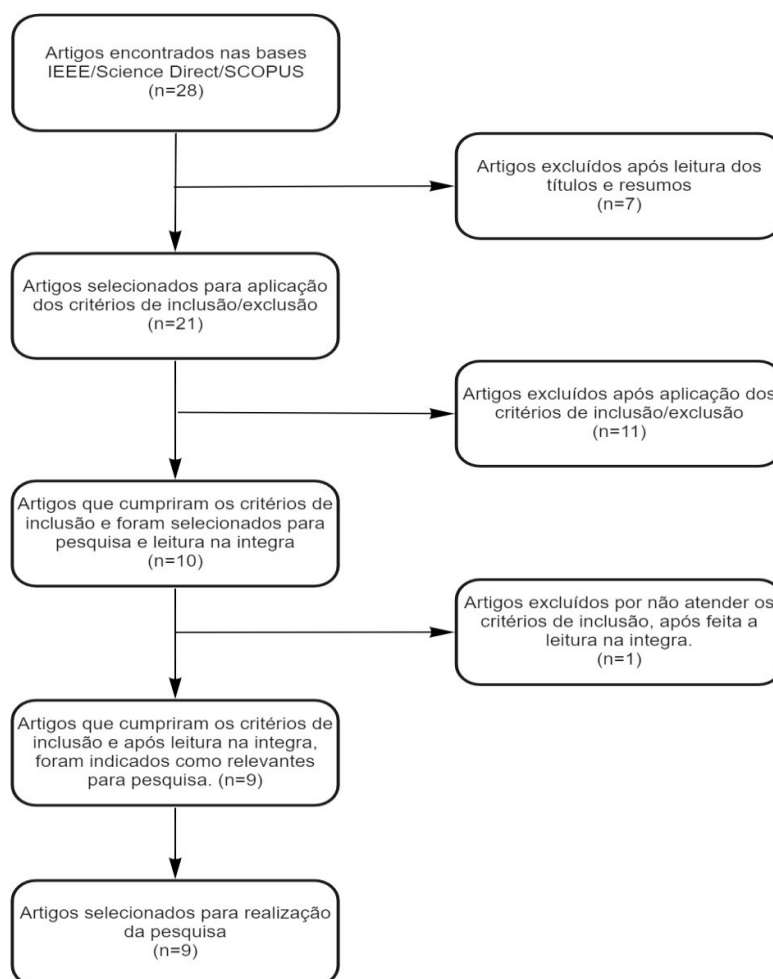
Neste capítulo, serão detalhados os procedimentos utilizados durante a extração de informações dos artigos, explicitando desde o período temporal dos artigos publicados, até como foi o procedimento de escolha das *strings*. Além disso, é possível observar os artigos pré-selecionados nas buscas realizadas nas bases de dados (IEEE, *ScienceDirect* e Scopus), subdivididos em quadros de artigos incluídos e excluídos da pesquisa.

Por meio da análise dos artigos publicados nos últimos 10 anos, pode-se observar o aumento no decorrer dos últimos 4 anos em relação ao número de pesquisas referentes ao uso de redes neurais aplicadas a qualidade da gasolina. Com isso, verifica-se que a aplicação das redes neurais nesta área vem sendo cada vez mais relevante para busca de melhorias nos métodos de análise.

Diante do exposto, foi elaborado um algoritmo em forma de fluxograma para o entendimento sobre a extração dos resultados encontrados nas bases de dados do IEEE, SCOPUS e *ScienceDirect*.

Em seguida, é demonstrado os resultados referentes ao número de artigos encontrados em cada *string* de busca, dentro do período delimitado de 2012 a 2022 nas bases de dados previamente citadas (IEEE, *ScienceDirect* e Scopus).

**Fluxograma 2: Procedimento realizado com os resultados encontrados nas bases de dados**



**Fonte: Autoria própria (2022)**

### Analytical Models

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":octane number prediction): 2012-2022 - IEEE (0 Artigos encontrados)

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":antiknock performace): 2012-2022 – IEEE (0 Artigos encontrados)

("All Metadata":gasoline) AND ("All Metadata":neural network) AND ("All Metadata":density): 2012-2022 – IEEE (0 Artigos encontrados)

gasoline AND "neural network" AND "octane number prediction": 2012-2022 – ScienceDirect (8 Artigos encontrados)

gasoline AND "neural network" AND "antiknock performace": 2012-2022 – ScienceDirect (3 Artigos encontrados)

gasoline AND "neural network" AND "density": 2012-2022 – ScienceDirect (3 Artigos encontrados)

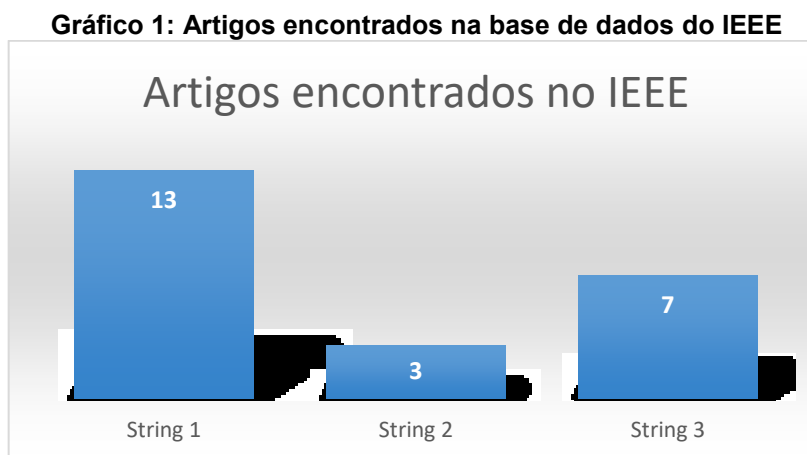
gasoline AND "neural network" AND "octane number prediction": 2012-2022 – Scopus (5 Artigos encontrados)

gasoline AND "neural network" AND "antiknock performace": 2012-2022 - Scopus (0 Artigos encontrados)

gasoline AND "neural network" AND "density": 2012-2022 – Scopus (4 Artigos encontrados)

Abaixo pode ser observado por meio de representações gráficas, os artigos encontrados em cada base de dados, sem a aplicação dos critérios de inclusão/exclusão, agrupados por *string* utilizada. Sendo considerada como a *string* 1: *gasoline, neural network, octane number prediction*, a *string* 2: *gasoline, neural network, antiknock performance*, e a *string* 3: *gasoline, neural network, density*.


O Gráfico 1 representa o quantitativo de artigos encontrados por *string* de busca no IEEE. É exposto que foram encontrados 13 artigos na *string* 1, 3 na *string* 2 e 7 na *string* 3.



Fonte: Autoria própria (2022)

O Gráfico 2 representa o quantitativo de artigos encontrados por *string* de busca no *ScienceDirect*. É possível observar que houve um total de 8 artigos encontrados na operacionalização da *string* 1, 3 na *string* 2 e 7 na *string* 3.


**Gráfico 2: Artigos encontrados na base de dados do ScienceDirect**



Fonte: Autoria própria (2022)

O Gráfico 3 representa o quantitativo de artigos encontrados por *string* de busca no Scopus. Observa-se que foram encontrados 5 artigos na *string* 1, nenhum artigo na *string* 2 e 4 artigos na *string* 3.

**Gráfico 3: Artigos encontrados na base de dados do Scopus**




Fonte: Autoria própria (2022)

O Gráfico 4 representa o quantitativo de artigos encontrados por *string* de busca

nas bases de dados. Verifica-se que foram encontrados 13 artigos na *string* 1, 3 na *string* 2 e 7 na *string* 3 em todas bases de dados selecionadas para esta pesquisa.

**Gráfico 4: Artigos encontrados nas bases de dados**



**Fonte: Autoria própria (2022)**

Na sequência, todos os artigos selecionados foram estudados e comentados em dois subtópicos (Modelos de RNAs aplicados no estudo das propriedades da gasolina e Estudos sobre desenvolvimento de modelos de RNA para prever propriedades da gasolina) criados a partir de seus objetivos principais.

### **5.1 Aspectos relevantes condizentes a pesquisa**

Nos últimos anos, o uso de softwares e técnicas de informática estão sendo usadas de maneira exponencial, visando a redução do tempo de análise e falhas operacionais que os funcionários cometem na realização manual dos cálculos. Com isso, o uso das redes neurais artificiais vem evoluindo e ganhando espaço em fatores que necessitam uma forma rápida e eficaz de generalização e aprendizagem.

Sendo assim, a pesquisa sobre o uso de redes neurais no controle de qualidade da gasolina demonstrou um aumento do uso das redes neurais para diversos campos de pesquisa, entre eles o da predição de parâmetros dos componentes da gasolina comercializada em postos de combustíveis.

Com intuito de selecionar artigos condizentes com o objetivo principal desta pesquisa, numa abordagem inicial, a *string* de busca utilizada foi “*gasoline*” and “*neural network*” para os últimos 10 anos de publicações, porém por apresentar uma quantidade imensa de resultados nas bases de dados escolhidas para pesquisa, tornava-se uma busca inviável devido ao tempo demandado, e também a maioria dos artigos que foram verificados espelhavam-se irrelevantes para pesquisa.

Neste contexto, a busca por artigos científicos nas bases de dados foi refinada, utilizando as principais propriedades analisadas durante o processo de inspeção da qualidade da gasolina, ou seja, substituiu-se o “*quality*” (do português qualidade) por ser muito abrangente, e foram adicionadas nas *strings*, as palavras-chaves: *octane number prediction*, *antiknock performace* e *density*, por serem características que influenciam diretamente na qualidade final da gasolina.

Estas palavras chave possibilitaram a criação de três *strings* de busca nas bases de dados Scopus, IEEE e *ScienceDirect* conforme detalhado anteriormente. Esta estratégia de busca possibilitou filtrar vários artigos irrelevantes, que fugiam da temática e do objetivo desta pesquisa, os quais eram resultados da *string* inicial contida apenas por “*gasoline*” and “*neural network*” and “*quality*”. Sendo assim, por meio deste método ocorreu a seleção dos artigos utilizados como base para realização desta pesquisa.

Assim, foram construídas tabelas para melhor interpretação e seleção dos artigos retirados de cada base de dados. Por meio das tabelas, foi possível realizar a exclusão dos artigos repetidos, além de aplicar os critérios de inclusão e exclusão já apresentados anteriormente no tópico da metodologia.

A seguir, no quadro 1, são apresentados os artigos que não atenderam os critérios de inclusão, e por tanto foram excluídos do estudo desta pesquisa de revisão da literatura.

Quadro 1: Artigos descartados da pesquisa

#	Autores	Título	Fonte	Critérios de Exclusão
1	WAN J.; HAN Z.; LIU, K. (2015)	RON predicted of gasoline by NIR based on ICA and SVM	IEEE	g, i, k
2	AHMAD, I.; ALI, G.; BILAL, M.; <i>et al.</i> (2018)	Virtual sensing of catalytic naphtha reforming process under uncertain feed conditions	IEEE	k
3	CHEN, X.; SHI, X.; TONG, C.; <i>et al.</i> (2018)	Prediction of Octane Number of Gasoline Based on Improved Extreme Learning Machine	IEEE	g, i, k
4	CHEN, Y. (2020)	Analysis of the Gasoline Octane Number Based on Neural Network	IEEE	k
5	LI, G.; ZHANG, H.; FAN, L.; <i>et al.</i> (2021)	A Novel Control Method Combining Multi-Level Dimension Reduction and NSGA-II for Octane Number	IEEE	k
6	LIU, Y.; XIONG, T. (2021)	Prediction of octane number loss based on Kernel-PCA and BP-MLP	IEEE	k
7	WANG, X.; YANG, K.; KALIVAS, J. H. (2020)	Comparison of extreme learning machine models for gasoline octane number forecasting by near-infrared spectra analysis	<i>Science Direct</i>	g, i
8	ZHU, Z.; ZHENG, Z.; KONG, J. (2021)	Construction of reduced mechanism and prediction of the RON of toluene primary reference fuel/ethanol/diisobutylene	<i>Science Direct</i>	g
9	AL IBRAHIM, E.; FAROOQ, A. (2020)	Octane Prediction from Infrared Spectroscopic Data	Scopus	l
10	YAVARI, H.; KHOSRAVANI, R.; WOOD, D. A.; <i>et al.</i> (2021)	Application of mathematical and machine learning models to predict differential pressure of autonomous downhole inflow control devices	Scopus	g, h, i
11	LI, W.; YANG, J.;	Characteristic Selection	Scopus	g, i

	YANG, P.; <i>et al.</i> (2021)	and Prediction of Octane Number Loss in Gasoline Refinement Process		
12	FU, N.; LAI, Z.; ZHANG, Y.; <i>et al.</i> (2021)	An effective method based on multi-model fusion for research octane number prediction	Scopus	k
13	ZHANG, Z. (2021)	Research on Forecast of Gasoline Octane Loss Based on Neural Network	Scopus	j

e - Foram excluídos pôsteres e livros; f - Excluídas pesquisas que apresentam avaliações sem apresentar o método utilizado; g - Excluídos estudos que não atendam os objetivos de estudo; h - Foram excluídas pesquisas que não apresentam resultados consistentes da inspeção da gasolina; i - Excluídas pesquisas que não utilizam RNA no processo de inspeção; j - Excluídos artigos com SNIP menor que 0,5; k - Foram excluídos artigos que não possuem acesso livre; l - Foram excluídas pesquisas que não descrevem a estrutura da RNA utilizada.

**Fonte: Autoria própria (2022)**

Durante o processo de extração dos artigos, foi possível observar o número de pesquisas referentes a predição da qualidade da gasolina por meio de redes neurais ao longo dos anos 2012-2022. Abaixo o quadro 2, expõe os artigos selecionados para leitura e condução desta pesquisa:

**Quadro 2: Artigos selecionados para a pesquisa**

#	Autores	Título	Fonte	Crítérios de inclusão
1	BASSAM, A.; CONDE-GUTIERREZ, R.A.; CASTILLO, J.; <i>et al.</i> (2014)	Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement	<i>Science Direct</i>	a, b, c, d
2	ELFGHI, F. M. (2016)	A hybrid statistical approach for modeling and optimization of RON: A comparative study and combined application of response surface methodology (RSM) and artificial neural network (ANN) based on design of experiment (DOE)	<i>Science Direct</i>	a, b, c, d



3	WANG, S.; LIU, S.; ZHANG, J.; <i>et al.</i> (2020)	Feasibility study on prediction of gasoline octane number using NIR spectroscopy combined with manifold learning and neural network	Science Direct	a, b, c, d
4	FENG, H.; ZHANG Z.; GAO, N.; <i>et al.</i> (2022)	Numerical study on the blending of excellent anti-knock fuel using artificial neural network	Science Direct	a, b, c, d
5	CUI, Y.; LIU, H.; WANG, Q.; <i>et al.</i> (2022)	Investigation on the ignition delay prediction model of multi-component surrogates based on back propagation (BP) neural network	Science Direct	a, b, c, d
6	WU, Y.; LIU, Y.; LI, X.; <i>et al.</i> (2022)	Gasoline octane number prediction from near-infrared spectroscopy with an ANN-based model	Science Direct	a, b, c, d
7	ABDUL JAMEEL, A. G.; OUDENHOVEN, V. V.; EMWAS, A.; <i>et al.</i> (2018)	Predicting Octane Number Using Nuclear Magnetic Resonance Spectroscopy and Artificial Neural Networks	Scopus	a, b, c, d
8	TAO, X.; LIU, Y.; LI, H.; <i>et al.</i> (2022)	Applying Machine Learning to Chemical Industry: A Self-Adaptive GA-BP Neural Network-Based Predictor of Gasoline Octane Number	Scopus	a, b, c, d

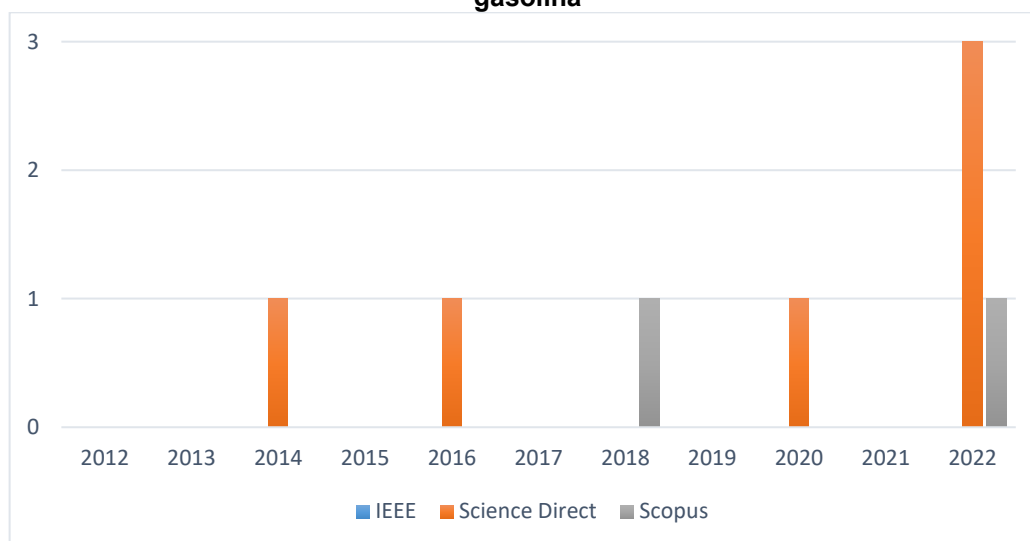
a - Textos completos, na língua inglesa com acesso livre e gratuito nas bases de dados previamente citadas; b - Incluídos trabalhos (publicados no período de 2012-2022) que possuam aprovação pela comunidade científica; c - Foram exigidos trabalhos publicados em periódicos com SNIP maior ou igual a 0,5; d - Utilizou-se trabalhos que abordaram sobre os métodos de análise da gasolina com RNAs;

**Fonte: Autoria própria (2022)**

Levando em conta o ano de publicação dos artigos selecionados, uma análise quantitativa em relação ao movimento da literatura acerca da *string 1 (gasoline, neural network and octane number prediction)*, *string 2 (gasoline, neural network, antiknock performance)* e *string 3: gasoline, neural network, density*). Neste sentido é possível inferir que com relação aos anos das publicações encontradas, dentro do período proposto, nas bases de dados do IEEE, *ScienceDirect* e Scopus é possível observar em 2014 o primeiro artigo que aborda esta temática e que em 2022 foi o ápice de publicações quando comparado aos anos anteriores.

Levando em consideração a duplicidade de publicações encontradas na busca da *string 2* e *string 3* em relação aos artigos obtidos *a priori* através da *string 1*, o Gráfico 5 abaixo apresenta dados referentes aos anos de publicações dos artigos selecionados para o estudo:

**Gráfico 5: Publicações da utilização de redes neurais artificiais na análise da qualidade da gasolina**



**Fonte: Autoria própria (2022)**

Por meio da análise do Gráfico 5, é possível afirmar que as publicações referentes as RNAs aplicadas no controle de qualidade da gasolina ganharam destaque no ano de 2022. Como pode-se observar, a base de dados do IEEE não teve artigos selecionados para o estudo em virtude do critério de inclusão “a”, que menciona a seleção dos artigos que possuam acesso livre e gratuito nas bases de dados. Com base nos resultados encontrados, identificamos que os artigos poderiam ser agrupados em duas categorias possíveis: a aplicações de redes neurais no estudo das propriedades da gasolina e outra sobre pesquisas de desenvolvimento de modelos de RNA para prever propriedades da gasolina. Foram subdivididos e comentados aqui os artigos selecionados na aplicação dos critérios de inclusão e exclusão, para ser possível verificar o que mais se tem feito dentro da área de análise da gasolina:

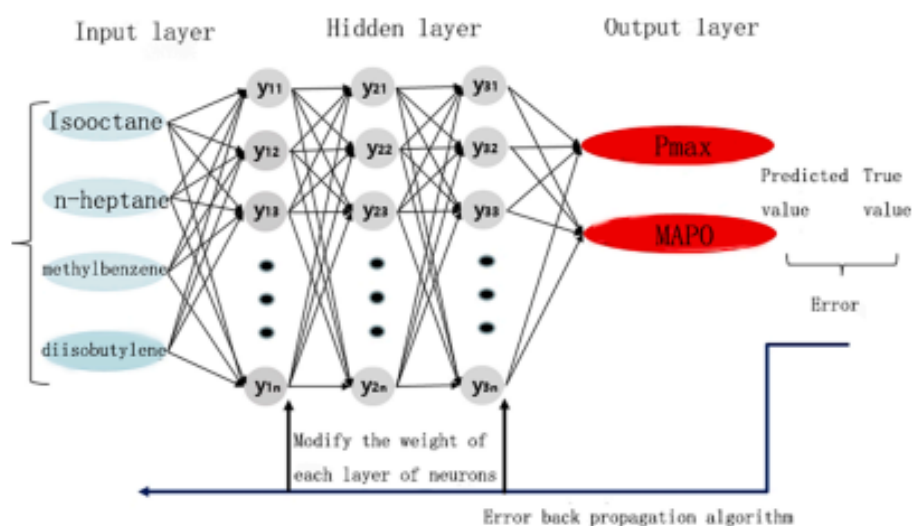
#### 1- Modelos de RNAs aplicados no estudo das propriedades da gasolina

A pesquisa experimental desenvolvida por Feng *et al.* (2021), aplicaram a Rede Neural *Backpropagation* (RNA BP) para otimização dos componentes da gasolina no

motor turbo de um veículo chinês.

Os autores utilizaram a RNA BP (Figura 6), contando com 4 neurônios na camada de entrada (representados pelos compostos iso-octano, n-heptano, tolueno e di-isobutileno), 8 neurônios na camada oculta e 2 neurônios na camada de saída (representada pelo valor máximo do pico de pressão e da oscilação de pressão no cilindro), com uma função de ativação ReLU (*Rectified Linear Units*), empregada nos neurônios da camada oculta. A Figura 6 representa a estrutura do modelo de RNA BP utilizada nesta pesquisa:

**Figura 6: Arquitetura do modelo de rede neural *Backpropagation***



Fonte: Feng *et al.*, (2021 p. 3)

O melhor desempenho do modelo apresentado, foi obtido por meio do cálculo do *Root Mean Square Error* (RMSE) e a *Mean Absolute Error* (MAE), que resultaram em 0,63 para o RMSE e 0,54 do MAE, quando utilizados um número de 8 neurônios e um otimizador *Stochastic Gradient Descent* (SGD).

Com a aplicação do modelo, a pesquisa obteve resultados consistentes ao verificar os quatro compostos influentes na octanagem da gasolina (iso-octano, n-heptano, tolueno e di-isobutileno), e por meio da plotagem de gráficos foi possível observar uma influência direta nos resultados obtidos do valor máximo do pico de pressão e da oscilação de pressão no cilindro com o IAD da gasolina.

Em pesquisa relacionada Wang *et al.* (2019) objetivou prever o número de octanas com a Espectrometria de Infravermelho Próximo (NIR) combinando algoritmo

de redução dimensional com RNA BP.

A rede neural conta com 3 neurônios na camada de entrada (compostos com maior relevância nos dados de octanagem), 9 neurônios na camada oculta e uma camada de saída na forma linear (representando o número de octanas). Considerou-se o algoritmo L-Isomap para redução da dimensionalidade dos dados inseridos na camada de entrada e para verificação do desempenho foi aplicado o cálculo de *Mean Square Error* (MSE) que atingiu resultados de até 0,025 e comprovou o desempenho preditivo do modelo adequado com 9 neurônios na camada oculta.

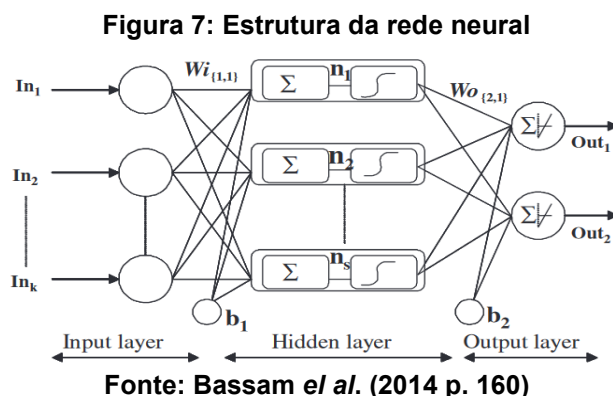
Diante disso, a pesquisa apresentou uma nova estratégia de espectroscopia NIR, capaz de prever o número de octanas da gasolina com alta precisão sendo eficiente na predição dos dados da octanagem e a L-Isomap permite realizar a redução de dimensão de dados de 401 compostos para 3, reduzindo efetivamente as informações redundantes e retendo as que possuem características com dados da octanagem, possibilitando uma redução no tempo de análise.

2- Estudos sobre desenvolvimento de modelos de RNA para prever propriedades da gasolina

Bassam *et al.* (2014) desenvolveram um modelo usando *Artificial Neural Network Backpropagation* (ANN BP) para prever o comportamento das curvas de ruptura dos parâmetros experimentais da nafta para promover a melhoria no índice de octanagem da gasolina.

Os autores utilizaram uma ANN BP (Figura 7) com 4 neurônios na camada de entrada (representados pelas propriedades da nafta: temperatura experimental (T), temperatura de adsorção (t), número de octanas (RON) e densidade dos hidrocarbonetos (q), e uma camada de saída constituída por um neurônio representado pela variável “C/Co” (concentração no tempo t dividida pela concentração inicial). Em relação a camada oculta, a rede neural apresentou um bom desempenho na utilização de 22 neurônios ocultos, calculados e analisados pela tangente hiperbólica de função sigmoide (TANSIG) e a função linear PURELIN na camada de saída.

Abaixo está a Figura 7, que ilustra a estrutura da RNA usada nesta pesquisa:



A estrutura ótima foi identificada como 4-22-1, contando com um otimizador Levenberg-Marquardt (LM) alcançou um desempenho preditivo ótimo, com eficiência de 0,96 e erro percentual médio (MPE) de 5%. Na análise de 1110 amostras de parafinas lineares e ramificadas, 666 amostras (60%) delas foram utilizadas para o treinamento e 444 (40%) para validação e teste das amostras, por meio das variações dos dados de entrada, de 175, 200, 225, 250, 300 e 325°C na temperatura de adsorção, 4,34 a 8,81 min nos tempos de adsorção, 53-100 número de octanas de hidrocarbonetos na nafta e densidade variando de 649 a 719 g/L.

Diante disso, a pesquisa demonstrou que todas variáveis inseridas na camada de entrada têm influência nos valores finais de concentração C/Co, sendo que as propriedades com maior contribuição nos resultados finais foram a densidade e a octanagem dos hidrocarbonetos. Com isso, a RNA BP foi capaz de prever as curvas de ruptura das variáveis experimentais em um processo de adsorção, com boa capacidade de generalização.

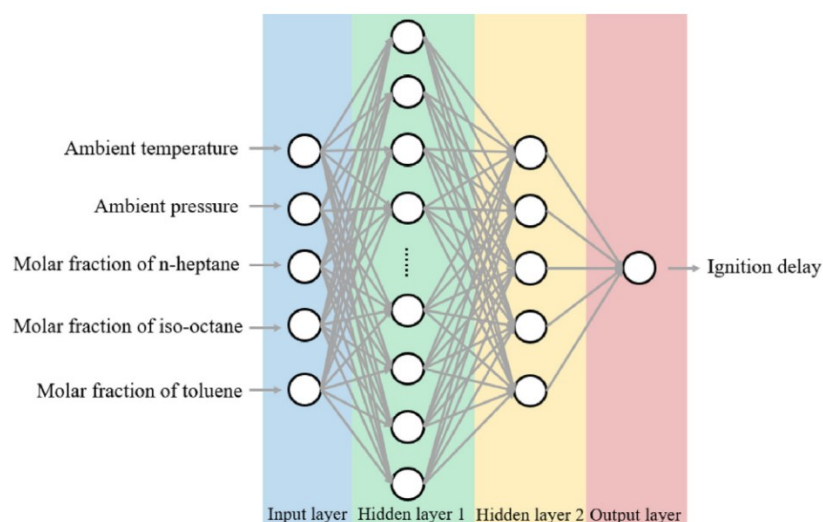
Ainda na perspectiva da análise da qualidade da gasolina por meio de RNAs, Cui *et al.* (2021) desenvolveram um modelo de RNA BP para prever o atraso de ignição de substitutos de três componentes sob diferentes condições de contorno e frações molares.

O experimento contou com uma RNA BP (Figura 8), contendo uma camada de entrada com 5 neurônios (representados pelos dados de entrada de temperatura ambiente, pressão ambiente, fração de n-heptano, fração molar de iso-octano e fração molar de tolueno), uma camada de saída na forma linear (1 neurônio) representado pelo atraso de ignição. Sendo que, o melhor desempenho preditivo testado foi adquirido utilizando duas camadas ocultas contando com 16 e 5 neurônios, que apresentaram um *Mean Relative Error* (MRE) de 2% e MSE de 0,09. Além disso, para

melhorar a precisão da RNA, o otimizador *Genetic Algorithm* (GA) e o *Particle Swarm Optimization* (PSO) foram utilizados.

Abaixo é ilustrada a Figura 8 com a representação da estrutura da RNA BP utilizada nesta pesquisa:

**Figura 8: Estrutura da rede neural BP (*Backpropagation*)**



**Fonte: Cui *et al.* (2021, p. 3)**

Nesse modelo de aprendizado os 5261 grupos de atraso de ignição de simulação 0-D de substitutos de componente único e de dois componentes, foram inseridas no algoritmo LM para treinamento e validação dos dados, utilizando 263 grupos de atraso (5%) como conjunto de validação e 4998 (95%) no conjunto de treinamento.

Em relação a análise da previsão de octanagem, fica evidente nos resultados apresentados que o retardo de ignição tem influência direta com o número de octanas do combustível, demonstrando a relevância do experimento. Diante disso, os autores modelaram uma RNA BP para previsão de atraso de ignição de três componentes, os quais apresentaram bom desempenho, aliado a um baixo tempo de análise que possibilitou prever os dados do atraso de ignição, e por meio deles, obter o número de octanas do combustível.

Utilizando uma ideia de previsão semelhante, a pesquisa experimental desenvolvida por Elfgui *et al.* (2016), modelou e otimizou as condições do processo da nafta por meio da aplicação combinada de RNA combinado a *Response Surface Methodology* (RSM) para prever o RON máximo sobre catalisador bimetálico, através

da reforma de compostos.

A pesquisa usou um modelo de estrutura *feed-forward* com *multilayer perceptron* (MLP) e a Rede Neural de Função de Base Radial (RBF), com uma camada de entrada de 3 neurônios (representados pela temperatura, pressão e velocidade espacial do processo da nafta), uma camada de saída de 1 neurônio (representada pelo número de octanas) e 11 neurônios na camada oculta determinados por tentativa e erro. Eles consideraram a RBF com otimizador de função de transferência gaussiana, Rede Neural de Função de Base Radial com função de (RBFT) e estrutura 3-11-1 por atingir um RMSE de 9.99 E-10, e ser considerada a estrutura ótima.

Em vista que, o RBF tem vantagens em relação ao RSM, tanto para ajuste de dados quanto recursos de estimativa, mas desvantagens por possuir técnicas defasadas de visualização, a junção dos modelos possibilitou descartar estas desvantagens. Também com intenção de melhorar o desempenho de predição da octanagem, um algoritmo função de transferência gaussiana é responsável pelo treinamento da rede neural resultando numa versão aprimorada da RBF, ou seja, a RBFT.

Diante disso, o experimento realizado por meio do estudo comparativo do desempenho na estimativa do RON entre o RSM e RBF, quando acoplados, o modelo fornece boa predição. Este experimento utilizou em conjunto os métodos com a intenção de minimizar o número de experimentos, sendo possível prever o RON, verificando que a temperatura de reação e pressão de operação representadas em uma velocidade espacial fixa tem relação direta no aumento do RON, ou seja, à medida que a temperatura e a pressão aumentam o RON atinge valores maiores.

Wu *et al.* (2022), realizaram a construção de um modelo de RNA para previsão do RON da gasolina e aplicaram em regiões da China comparando os resultados obtidos com os dados das amostras de gasolina coletadas.

O modelo de RNA contou com 34 dados de entrada, e uma saída na forma linear (representada pelo RON). O número de neurônios utilizados nas camadas ocultas para estrutura ótima foi de 15 na primeira camada e 8 na segunda camada, estabelecendo-se uma estrutura de 34-15-8-1. O modelo foi otimizado pelo *Partial Least Squares Regression* (PSLR), o qual ajustou o número de fatores *Partial Least Squares* (PLS) para entrada e expandiu o conjunto de treinamento, contando com

duas funções de ativação do tipo *Rectified Linear Unit* (ReLU) e *Exponential Linear Unit* (ELU) utilizadas na conversão de entrada para saída.

Neste contexto, em um grupo de 813 tipos de gasolina, sendo consideradas 613 como grupo de treinamento e 200 para validação dos dados, a RNA apresentou boa precisão com um MSE de 0,125, MAE de 1,367 e um *Coefficient of determination* ( $R^2$ ) de 0,97, mostrando melhorias na faixa de erro experimental quando a *Artificial Neural Network* (ANN) é utilizada em conjunto com o PLSR, atingindo resultados melhores que a RNA não modificada e suportando a análise de um número maior de amostras que os demais modelos.

Abdul *et al.* (2018), buscaram desenvolver modelos de RNAs e *Nuclear Magnetic Resonance* (NMR), para previsão do RON e MON de 123 misturas hidrocarboneto-etanol de composição conhecida e 30 misturas gasolina-etanol tipo FACE (combustíveis para motores de combustão avançados) foram utilizados como um conjunto de dados para desenvolver o modelo ANN.

Os dados de entradas dos modelos de redes neurais foram selecionados utilizando técnicas analíticas de espectroscopia de infravermelho com transformada de Fourier (FTIR), espectroscopia de emissão de chama, espectroscopia de NMR e espectroscopia Raman de fibra óptica dispersiva.

Foram desenvolvidos dois modelos de RNA que contam com 9 neurônios de entrada (representados por grupos parafínicos  $\text{CH}_3$ ,  $\text{CH}_2$  e  $\text{CH}$ , grupos  $\text{CH}=\text{CH}_2$  olefínicos, grupos  $\text{CH}-\text{CH}_2$  naftênicos, grupos  $\text{C}-\text{CH}$  aromáticos e grupos álcoois  $\text{OH}$ , juntamente com índice de ramificação (BI) e peso molecular (MW)). Contou também com uma camada de saída representada pelo RON, a qual foram utilizadas duas camadas ocultas de 540 e outra de 314 neurônios, ou seja, a rede ótima foi definida em 9-540-314-1, com a utilização de 123 misturas hidrocarboneto-etanol e 30 misturas gasolina-etanol tipo FACE. Neste sentido, para o segundo modelo de RNA, foram mantidas as mesmas quantidades de neurônios na entrada e saída, sendo que o neurônio de saída neste é representado por MON, porém as camadas ocultas obtiveram melhor desempenho com o número de 340 na primeira camada oculta e 603 na segunda camada oculta, ou seja, a rede ótima para o segundo modelo foi definida em 9-340-603-1.

Ambos modelos foram capazes de prever o RON e MON de uma amostragem de 30 gasolinas tipo FACE (combustíveis para motores de combustão

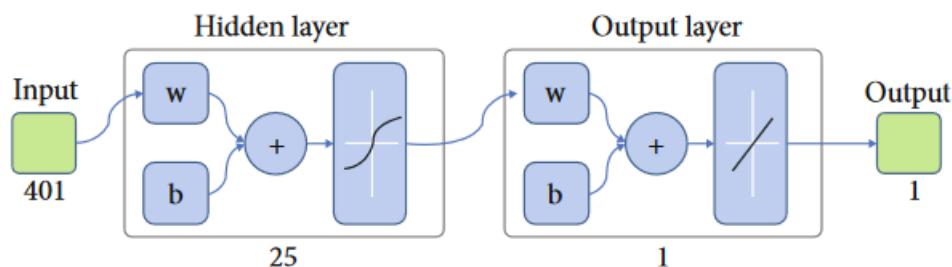


avançados), apresentando uma boa correlação entre a previsão calculada e o valor experimental, sendo que o MAE encontrado foi de 1,2 o qual é um resultado próximo a faixa de incerteza experimental, evidenciando que os grupos funcionais do combustível podem ser usadas para previsão da octanagem.

Tao *et al.* (2022) em uma pesquisa experimental propuseram um novo modelo de previsão da octanagem em RNA BP, com base na otimização de algoritmo GA com índices físicos e químicos da gasolina como suas variáveis independentes e octanagem como sua variável dependente.

A estrutura da RNA BP mais adequada ficou estabelecida com 401 neurônios de entrada (representados pelos 401 compostos presentes na gasolina), 1 neurônio de saída (representado pelo número de octanas), e 25 neurônios ocultos determinados por meio de uma fórmula empírica desenvolvida. Além disso, o modelo contou com um algoritmo otimizador GA e com uma função de ativação do tipo sigmoide na camada oculta e função linear inserida na camada de saída. Abaixo está a Figura 9 referente ao modelo desenvolvido:

**Figura 9: Estrutura do modelo de rede neural BP desenvolvido**



Fonte: Tao *et al.* (2022, p. 5)

O treinamento do modelo foi realizado utilizando *Self-Adaptive Genetic Algorithm* (GA) em um grupo de 60 amostras de gasolina e selecionadas por espectroscopia NIR, sendo 50 delas para o treinamento e 10 para validação.

Os valores previstos comparados com a octanagem real da gasolina no conjunto de dados e o índice de desempenho da rede neural demonstrou ser adequado, superando limitações da versão tradicional de baixa precisão da previsão. Sendo assim, a RNA BP otimizada no algoritmo genético (GA-BP) alcança um desempenho de 0,95628 no  $R^2$  e o erro de previsão média (AEE) foi reduzido de 0,0061 para 0,0041, demonstrando uma melhoria na previsão.

Diante disso, o modelo é capaz de prever o número de octanas da gasolina com melhor desempenho, maior precisão, capacidade de generalização e erro de previsão média cerca de 14% melhor em relação ao modelo tradicional de BP.

## 6 CONCLUSÃO

A pesquisa buscou analisar por meio de uma revisão sistemática da literatura os métodos de controle da qualidade da gasolina com uso de RNAs que foram publicados entre os anos de 2012 a 2022. De maneira que, foi possível identificar que os modelos de RNA que foram mais utilizados para o quesito análise/controle da qualidade são a RNA BP e RBF, por apresentarem vantagens no ajuste de dados, generalização, tempo de análise, desempenho nos resultados e uma boa predição.

Estabelecer as categorias empíricas possibilitou compreender que as pesquisas que modificaram a estrutura dos modelos de RNA obtiveram melhor desempenho, partindo do pressuposto de que o erro médio do resultado final foi menor em relação aos modelos que utilizaram RNAs pré-determinadas na literatura, ou seja, foram mais eficazes no processamento dos cálculos de previsão dos compostos.

As RNAs que passam por um treinamento prévio e que são submetidas a alterações em sua estrutura, como os modelos mencionados anteriormente, são aptas a realizar testes de qualidade da gasolina com precisão e bom desempenho, além de permitir o uso de otimizadores e funções de ativação que tem influência na minimização do erro percentual dos resultados fornecidos.

Diante do exposto, esta pesquisa permitiu identificar quais os modelos de RNA e adaptações da estrutura são mais indicados para a análise da qualidade da gasolina, além de demonstrar que para obter resultados precisos as RNAs necessitam de algoritmos de treinamento adequado e modificações na estrutura. Logo, em um cenário que onde o método fosse implantado pela ANP, possivelmente falhas humanas e tempo prolongado de análise poderiam ser superados, permitindo uma fiscalização mais eficaz no território brasileiro.

Sugestão para trabalhos futuros:

- Aplicar o uso da RNA na análise dos compostos da gasolina como forma de comprovar os dados obtidos pelo teste da proveta (método padrão da ANP);
- Modelar as RNAs BP e RBF para comparar o desempenho apresentado entre os dois modelos, utilizando um mesmo grupo de compostos inseridos na gasolina.

## REFERÊNCIAS

ABDELKHALEK, H. S.; MEDHAT, H.; *et al.* Simulation and prediction for a satellite temperature sensor based on artificial neural network. **Journal of Aerospace Technology and Management**, v. 11, p. 1-14, 2019.

ABDUL JAMEEL, A. G.; OUDENHOVEN, V. V.; *et al.* Predicting Octane Number Using Nuclear Magnetic Resonance Spectroscopy and Artificial Neural Networks. **Energy & Fuels**, v. 32, n. 5, p. 6309-6329, 2018.

Agência Nacional de Petróleo, Gás e Biocombustíveis (ANP). Disponível em: <http://www.anp.gov.br/wwwanp>. Acesso em: 11 de setembro de 2022.

AGUIAR, T. C.; RAMOS, D. V. B.; CRISPIM, P. T. B.; *et al.* Aplicação de redes neurais artificiais na predição das temperaturas de destilação da gasolina. Congresso Brasileiro de Química, 2009. Disponível em: <http://www.abq.org.br/cbq/2009/trabalhos/13/13-488-4755.htm>. Acesso em: 16 de maio de 2022.

AHMAD, I.; ALI, G.; *et al.* Virtual sensing of catalytic naphtha reforming process under uncertain feed conditions. **2018 International Conference on Computing, Mathematics and Engineering Technologies (iCoMET)**. IEEE, 2018. p. 1-6. Disponível em: <<https://ieeexplore.ieee.org/document/8346447/>>. Acesso em: 4 agosto de 2022.

AL IBRAHIM, E.; FAROOQ, A. Octane Prediction from Infrared Spectroscopic Data. **Energy & Fuels**, v. 34, n. 1, p. 817-826, 2020.

ARAÚJO, H. G. C. **Estudo experimental sobre a qualidade da gasolina comercializada no estado da Paraíba com o uso da norma ABNT 13992: 2008 e do planejamento fatorial**. 93f. 2013. Dissertação (Mestrado em Engenharia Mecânica), Universidade Federal de Campina Grande. Campina Grande, 2013.

BASSAM, A.; CONDE-GUTIERREZ, R.A.; *et al.* Direct neural network modeling for separation of linear and branched paraffins by adsorption process for gasoline octane number improvement. **Fuel**, v. 124, p. 158-167, 2014.

BASTOS, E. N. F. **Uma Rede Neural Auto-Organizável Construtiva para Aprendizado Perpétuo de Padrões Espaço-Temporais**. 137f. 2007. Dissertação (Mestrado em Ciência da computação), Universidade Federal do Rio Grande do Sul. Porto Alegre, 2007.

BIOLCHINI, J.; MIAN, P. G.; *et al.* **Systematic review in software engineering. Tech. Report RT-ES**. Systems Engineering and Computer Science Dept., v. 679, n. 5, p. 45, 2005. Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2005.

BRAGA, A. de P. **Redes neurais artificiais: teoria e aplicações**. 2ed. 2007.

BRASIL. **Lei n. 737, de 23 de setembro de 1938**. Torna obrigatória a adição de álcool anidro à gasolina produzida no país, qualquer que seja o método ou processo de sua fabricação, e da outras providências. Rio de Janeiro, 1938. Disponível em: <https://www2.camara.leg.br/legin/fed/declei/1930-1939/decreto-lei-737-23-setembro-1938-350748-publicacaooriginal-1-pe.html>. Acesso em: 8 agosto, 2022a.

BRASIL. **Decreto nº 238, de 23 de setembro de 1938**. Coleção de Leis do Brasil, Brasília, DF, v. 3, p. 255. Disponível em: <https://www2.camara.leg.br/legin/fed/declei/1930-1939/decreto-lei-737-23-setembro-1938-350748-publicacaooriginal>. Acesso em: 20/04/2022b.

BRASIL, 2020. Gasolina – Informações Técnicas. Disponível em: <https://petrobras.com.br/data/files/02/93/A0/4C/5A39C710E2EF93B7B8E99EA8/manual-de-gasolina.pdf>. Acesso em: 26/04/2022a.

BRASIL. **Diário Oficial da União, Resolução nº 807, de 23 de janeiro de 2020**. Disponível em: <https://www.in.gov.br/en/web/dou/-/resolucao-n-807-de-23-de-janeiro-de-2020-239635261>. Acesso em: 26/04/2022b.

BRASIL. **Lei nº 13.033, de 24 de setembro de 2014**. Disponível em: [http://www.planalto.gov.br/ccivil\\_03/\\_Ato2011-2014/2014/Lei/L13033.htm](http://www.planalto.gov.br/ccivil_03/_Ato2011-2014/2014/Lei/L13033.htm). Acesso em: 27/04/2022.

BRASIL. **Lei nº 8.176, de 8 de fevereiro de 1991**. Disponível em: [https://www.planalto.gov.br/CCivil\\_03/leis/L8176.htm](https://www.planalto.gov.br/CCivil_03/leis/L8176.htm). Acesso em: 27/04/2022.

CARVALHO, A.; LUDEMIR, A. **Fundamentos de Redes Neurais Artificiais**. 11. ed. Rio de Janeiro: COPPE, 1998.

CARVALHO, F. I. M.; DANTAS FILHO, H. A. Estudo da qualidade da gasolina tipo A e sua composição química empregando análise de componentes principais. **Quim. Nova**, v. 37, n. 1, p. 33-38, 2014.

CARVALHO, V. P. **Previsão de Séries Temporais no Mercado Financeiro de Ações com o uso de Rede Neural Artificial**. 70f. 2018. Dissertação (Mestrado Engenharia Elétrica e Computação), Universidade Presbiteriana Mackenzie, São Paulo, 2018.

CHEN, X.; SHI, X.; *et al.* Prediction of Octane Number of Gasoline Based on Improved Extreme Learning Machine. **2018 37th Chinese Control Conference (CCC)**. Wuhan: Ningbo University, jul. 2018. Disponível em: <https://ieeexplore.ieee.org/document/8482538/>. Acesso em: 4 ago. 2022

CHEN, Y. Analysis of the Gasoline Octane Number Based on Neural Network. **2020 International Conference on Computing and Data Science (CDS)**. Stanford, CA, USA: Chongqing University. ago. 2020. p. 136-138. Disponível em: <https://ieeexplore.ieee.org/document/9275979/>.

CLEVERT, D.; UNTERTHINER, T.; *et al.* Fast and accurate deep network learning by exponential linear units (ELUS). **ICLR 2016**. Linz, Áustria: Kepler University. 2016.

COSTA, S. C. **Técnicas físico-químicas para caracterização da gasolina automotiva. Relatório de estágio do curso de graduação em Química do Petróleo**. 44f. 2021. Trabalho de Conclusão de curso (Bacharel em Química), Universidade Federal do Rio Grande do Norte, Natal, 2021.

CUI, Y.; LIU, H.; *et al.* Investigation on the ignition delay prediction model of multi-component surrogates based on back propagation (BP) neural network. **Combustion and Flame**, v. 237, p. 1-16, 2022.

DAGOSTIN, A. P. D., **Estudo da Contaminação da Gasolina com Solvente de Borracha**. 2003. 32f. Trabalho de Conclusão do Curso (Bacharel em Química), Universidade Federal de Santa Catarina, Florianópolis, 2003.

ELFGHI, F. M. A hybrid statistical approach for modeling and optimization of RON: A comparative study and combined application of response surface methodology (RSM) and artificial neural network (ANN) based on design of experiment (DOE). **Chemical Engineering Research and Design**, v. 113, p. 264-272, 2016.

FENG, H.; ZHANG, Z.; *et al.* Numerical study on the blending of excellent anti-knock fuel using artificial neural network. **Fuel**, v. 312, p. 18, 2022.

FERNEDA, E. Redes neurais e sua aplicação em sistemas de recuperação de informação. **Ciência da Informação**, v. 35, n. 1, p. 25-30, 2006.

FLECK, L.; TAVARES, M. H. F.; EYNG, E.; HELMANN, A. C.; ANDRADE, M. A. de M. Redes Neurais Artificiais: Princípios Básicos Artificial Neural Networks: Basic Principles. **Revista Eletrônica Científica Inovação e Tecnologia**, v. 1, n. 13, p. 47-57, 2016.

FU, N.; LAI, Z.; *et al.* An effective method based on multi-model fusion for research octane number prediction. **New Journal of Chemistry**, v. 21, n. 21, p.9668-9676, 2021.

HAYKIN, S. **Redes neurais: princípios e prática**. Trad. Paulo Martins Engel. 2. ed. Porto Alegre: Bookman, 2001.

LI, G.; ZHANG, H.; *et al.* A Novel Control Method Combining Multi-Level Dimension Reduction and NSGA-II for Octane Number. **2021 40th Chinese Control Conference (CCC)**. Shanghai, China: School of Electronics and Control Engineering, 26 jul. 2021. Disponível em: <<https://ieeexplore.ieee.org/document/9550230/>>.

LI, H.; ZHANG, Z.; *et al.* Application of artificial neural networks for catalysis: A review. **Catalysts**, v. 7, n. 10, p. 306, 2017.

LI, W.; YANG, J.; *et al.* Characteristic Selection and Prediction of Octane Number Loss in Gasoline Refinement Process. **E3S Web of Conferences**, v. 245, n. 1, p. 1-27, 2021.

LIMA, A. G.; GUERREIRO, A. N. G. Uso das redes neurais de função de base radial e Growing Neural Gás na classificação de imagens de sensoriamento remoto. Anais XV Simpósio Brasileiro de Sensoriamento Remoto - SBSR, Curitiba, PR, Brasil, 30 de abril a 05 de maio de 2011, INPE p.7247. Universidade Federal do Rio Grande do Norte. Natal (2011)

LIU, Y.; XIONG, T. Prediction of octane number loss based on Kernel-PCA and BP-MLP. **2021 6th International Conference on Intelligent Informatics and Biomedical Sciences (ICIIBMS)**. Oita, Japan: Shanghai Institute of Technology, 25 nov. 2021. Disponível em: <<https://ieeexplore.ieee.org/document/9651570/>>.

LOPES, D.; FARIAS, C.; SILVA, I.; BARBOSA, J. Utilização de redes neurais artificiais na utilização de padrões de sinais ultrassônicos. **V Congresso de Pesquisa e Inovação da Rede Norte Nordeste de Educação Tecnológica (CONNEPI)**. Salvador, Bahia: Instituto Federal de Educação Ciência e Tecnologia da Bahia, v. 1, n. 1, p. 1-12, 2009.

MAKIUCHI, M. R. **Desenvolvimento de Rede Neural Artificial Recorrente em FPGA para Previsão online de Oportunidades em Transmissões Oportunisticas em Redes de Comunicação Wireless**. 2018. 81f. Trabalho de conclusão de curso (Graduação em Engenharia de Controle e Automação), Universidade de Brasília, Brasília, 2018.

MENDES, A. P. A.; TEIXEIRA, C. A. N.; ROCIO, M. A. R.; *et al.* Mercado de refino de petróleo no Brasil. **BNDES**. Rio de Janeiro, v. 24, n. 48, p. 7-44, 2018.

MENESES, M. V. M.; **O efeito do monitoramento da fiscalização sobre a qualidade dos combustíveis automotivos**. 2019. 84f. Dissertação (Mestrado em Ciências Econômicas). Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2019.

MORAIS, E. C. **Reconhecimento de padrões e redes neurais artificiais em predição de estruturas secundárias de proteínas**. 2010. 148f. Tese (Doutorado em Engenharia de Sistemas e Computação). Universidade Federal do Rio de Janeiro. Rio de Janeiro, 2010.

NASCIMENTO, M. V.; SILVA, G. O.; LEMOS, A. J. Análise do teor de etanol na gasolina comercializada nos postos de combustíveis do município de Guaraí-TO. **Revista desafios**, v. 7, n. 2, p. 158-161, 2020.

OLIVEIRA, L. G. R. **Adulteração em combustíveis automotivos: Uma revisão sistemática**. 2018. 61f. Trabalho de conclusão de curso (Bacharel em Química do Petróleo), Universidade Federal do Rio Grande do Norte, Natal, 2018.

PASADAKIS, N.; GAGANIS, V.; FOTEINOPOULOS, C. Octane number prediction for gasoline blends. **Fuel Processing Technology**, v. 87, p. 505-509, 2006.

PINTO, V. D. A. **Gasolina: Uma proposta temática para estudo do petróleo no ensino de química**. 2012. 45f. Trabalho de conclusão de curso (Licenciatura em Química), Universidade de Brasília Instituto de Química, Brasília, 2012.

PRUDENTE, C. H. **Estudo da qualidade da gasolina em postos de abastecimento da cidade de Cândido Mota**. 2010. 36f. Trabalho de conclusão de curso (Graduação em Química), Instituto Municipal de Ensino Superior de Assis, Assis, 2010.

REIS, B. **Redes neurais - Funções de ativação**. 2016. Disponível em: <<http://www.decom.ufop.br/imobilis/redes-neurais-funcoes-de-ativacao/>> Acesso em: 10 de setembro de 2019.

RODRIGUES, M. L. R. **Qualidade da gasolina comercializada em municípios do baixo Parnaíba**. 2017. 47f. Monografia (Licenciatura em Ciências Naturais/Química), Universidade Federal do Maranhão, São Bernardo, 2017.

SAGAZ, M. M. **Estudo comparativo entre modelos em redes neurais e modelo bayesiano para consciência situacional**. 2021. 112f. Trabalho de conclusão de curso (Bacharel em Sistemas de Informação). Universidade Federal de Santa Catarina. Florianópolis, 2021.

SILVA, I. N.; SPATTI, D. H.; FLAUZINO, R. A.; *et al.* **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. 1. ed. São Paulo: Artliber, 2010.

SILVA, B. K. S. **Identificação de um sistema multitanques utilizando redes neurais de função de base radial**. 2016. 102f. Dissertação (Mestrado em ciência e engenharia de petróleo). Universidade Federal do Rio Grande do Norte. Natal, 2016.

SIMÕES, A. S. **Aprendizado não-supervisionado em redes neurais pulsadas de base radial**. Doutorado em Sistemas Digitais-São Paulo: Universidade de São Paulo, 2006.

TAKESHITA, E. V. **Adulteração de gasolina por adição de solventes: análise dos parâmetros físico-químicos**. 2006. 113f. Dissertação (Mestrado em Engenharia Química), Universidade Federal de Santa Catarina, Florianópolis, 2006.

TAO, X.; LIU, T., *et al.* Applying Machine Learning to Chemical Industry: A Self-Adaptive GA-BP Neural Network-Based Predictor of Gasoline Octane Number. **Mobile Information Systems**, v. 2022, p. 1-10, 2022.

VON ZUBEN, F. J.; ATTUX, R. R. F. **Redes Neurais com Funções de Ativação de Base Radial**. DCA/FEEC/Unicamp, 2001.

WAN, J.; HAN, Z., *et al.* RON predicted of gasoline by NIR based on ICA and SVM. **2015 12th International Computer Conference on Wavelet Active Media**



**Technology and Information Processing (ICCWAMTIP)**. Chengdu, China: University of Petroleum, dez. 2015. Disponível em: <<http://ieeexplore.ieee.org/document/7494039/>>.

WANG, S.; LIU, S.; *et al.* Feasibility study on prediction of gasoline octane number using NIR spectroscopy combined with manifold learning and neural network. **Spectrochimica Acta Part A: Molecular and Biomolecular Spectroscopy**, v. 228, p. 117-132, 2020.

WANG, X.; YANG, K.; *et al.* Comparison of extreme learning machine models for gasoline octane number forecasting by near-infrared spectra analysis. **Optik**, v. 200, p. 163-172, 2020.

WU, Y.; LIU, Y.; *et al.* Gasoline octane number prediction from near-infrared spectroscopy with an ANN-based model. **Fuel**, v. 318, p. 123-136, 2022.

YAVARI, H.; KHOSRAVANI, R.; *et al.* Application of mathematical and machine learning models to predict differential pressure of autonomous downhole inflow control devices. **Advances in Geo-Energy Research**, v. 5, n. 4, p. 386-406, 2021.

ZHANG, Z. Research on Forecast of Gasoline Octane Loss Based on Neural Network. **Journal of Physics: Conference Series**, v. 1802, n. 2, p. 225-237, 2021.

ZHU, Z.; ZHENG, Z.; *et al.* Construction of reduced mechanism and prediction of the RON of toluene primary reference fuel/ethanol/diisobutylene. **Renewable Energy**, v. 172, p. 862-881, 2021.

## APÊNDICE A

Fonte: IEEE						
String de Busca: Gasoline AND Neural Network AND Octane number prediction						
Data da Busca: 03/08/2022						
Nome do Trabalho	Autores	Informação Complementar	Incluído/Excluído	Ité-rios de In-clusão	Crité-rios de Ex-clusão	
				Questão Primária	E1 Descrição Critério Exclusão 1	En Descrição Critério Exclusão n
Virtual sensing of catalytic naphtha reforming process under uncertain feed conditions	AHMAD, I.; ALI, G.; BILAL, M.; et al.	[1]	[2]	[3]	[1], [2]	
Prediction of Octane Number of Gasoline Based on Improved Extreme Learning Machine	CHEN, X.; SHI, X.; TONG, C.; et al.	[1]	[2]	[3]	[1], [2]	
Analysis of the Gasoline Octane Number Based on Neural Network	CHEN, Y.	[1]	[2]	[3]	[1], [2]	
RON predicted of gasoline by NIR based on ICA and SVM	WAN, J.; HAN, Z.; LIU, K	[1]	[2]	[3]	[1], [2]	
A Novel Control Method Combining Multi-Level Dimension Reduction and NSGA-II for O	LI, G.; ZHANG, H.; FAN, L.; et al.	[1]	[2]	[3]	[1], [2]	
Prediction of octane number loss based on Kernel-PCA and BP-MLP	LIU, Y.; XIONG, T.	[1]	[2]	[3]	[1], [2]	
[1] Excluir: O trabalho foi excluído devido a não se apresentar na forma de artigo.						
[2] Excluir: O trabalho por estar apresentado num capítulo de livro não possui SNIP.						
[3] Não se aplica						

Fonte: Science Direct							
String de Busca:							
Gasoline AND Neural Network AND Octane number prediction							
Data da Busca:							
03/08/2022							
ID	Nome do Trabalho	Autores	Informação Complementar	Incluído/Excluído	Crterios de Inclus	Crterios de Exclusão	
					Questão Primária	E1 Descrição Critério Exclusão 1	En Descrição Critério Exclusão n
					Descrição Questão Primária		
1	Direct neural network modeling for separation of linear and branched paraffins by adsorption	BASSAM, A.; CONDE-GUTIERREZ, R.A.; CASTILLO		Incluído	[1], [2], [3], [4], [5]	[6]	
2	Investigation on the ignition delay prediction model of multi-component surrogates based on	CUI, Y.; LIU, H.; WANG, Q.; et al.		Incluído	[1], [2], [3], [4], [5]	[6]	
3	A hybrid statistical approach for modeling and optimization of RON: A comparative study a	ELFGHI, F. M.		Incluído	[1], [2], [3], [4], [5]	[6]	
4	Numerical study on the blending of excellent anti-knock fuel using artificial neural network	FENG, H.; ZHANG Z.; GAO, N.; et al.		Incluído	[1], [2], [3], [4], [5]	[6]	
5	Feasibility study on prediction of gasoline octane number using NIR spectroscopy combined	WANG, S.; LIU, S.; ZHANG, J.; et al.		Incluído	[1], [2], [3], [4], [5]	[6]	
6	Comparison of extreme learning machine models for gasoline octane number forecasting by	WANG, X.; YANG, K.; KALIVAS, J. H.		Incluído	[1], [2], [3], [4], [5]	[6]	
7	Gasoline octane number prediction from near-infrared spectroscopy with an ANN-based model	WU, Y.; LIU, Y.; LI, X.; et al.		Incluído	[1], [2], [3], [4], [5]	[6]	
8	Construction of reduced mechanism and prediction of the RON of toluene primary reference	ZHU, Z.; ZHENG, Z.; KONG, J.		Incluído	[1], [2], [3], [4], [5]	[6]	
[1] Incluir: Textos completos, na língua inglesa com acesso livre e gratuito nas bases de dados previamente citadas;							
[2] Incluir: Trabalhos (publicados no período de 2012-2022) que possuam aprovação pela comunidade científica;							
[3] Incluir: Trabalhos publicados em periódicos com Snip maior ou igual a 0,5;							
[4] Incluir: Trabalhos de RNAs que são usados para prever os parâmetros de qualidade do combustível;							
[5] Incluir: Trabalhos que abordem sobre os métodos de análise da gasolina com RNAs;							
[6] Não se aplica							

