



**UNIVERSIDADE DA INTEGRAÇÃO INTERNACIONAL DA LUSOFONIA AFRO-  
BRASILEIRA**  
**INSTITUTO DE ENGENHARIAS E DESENVOLVIMENTO  
SUSTENTÁVEL**  
**CURSO DE ENGENHARIA DE ENERGIAS**

**FRANCISCO LUCAS DE SOUZA MAGALHÃES**

**APLICAÇÕES DE REDES NEURAS ARTIFICIAIS NO ESTUDO DE PRODUÇÃO  
DE BIODIESEL: ESTIMAÇÃO DE PROPRIEDADES E PREVISÃO DE DEMANDA**

**Redenção-CE**

**2023**

**FRANCISCO LUCAS DE SOUZA MAGALHÃES**

**APLICAÇÕES DE REDES NEURAS ARTIFICIAIS NO ESTUDO DE PRODUÇÃO  
DE BIODIESEL: ESTIMAÇÃO DE PROPRIEDADES E PREVISÃO DE DEMANDA**

Trabalho de conclusão de curso apresentado ao curso de Engenharia de Energias da Universidade da Integração Internacional da Lusofonia Afro-Brasileira como requisito parcial à obtenção do título de Engenheiro de Energias.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Artemis Pessoa Guimarães.

Coorientador: Prof. Dr. Antônio Alisson Pessoa Guimarães.

**Redenção-CE**

**2023**

Universidade da Integração Internacional da Lusofonia Afro-Brasileira  
Sistema de Bibliotecas da UNILAB  
Catalogação de Publicação na Fonte.

---

Magalhães, Francisco Lucas de Souza.

M189a

Aplicações de redes neurais artificiais no estudo de produção de biodiesel: estimativa de propriedades e previsão de demanda / Francisco Lucas de Souza Magalhães. - Redenção, 2023.  
45fl: il.

Monografia - Curso de Engenharia de Energias, Instituto de Engenharias e Desenvolvimento Sustentável, Universidade da Integração Internacional da Lusofonia Afro-Brasileira, Redenção, 2023.

Orientadora: Prof.<sup>a</sup> Dr.<sup>a</sup> Artemis Pessoa Guimarães.

Coorientador: Antônio Alisson Pessoa Guimarães.

1. Redes Neurais Artificiais. 2. Viscosidade Cinemática. 3. Massa específica. 4. Biodiesel - Produção. I. Título

CE/UF/BSCA

CDD 662.756

---

**FRANCISCO LUCAS DE SOUZA MAGALHÃES**

**APLICAÇÕES DE REDES NEURAS ARTIFICIAIS NO ESTUDO DE PRODUÇÃO  
DE BIODIESEL: ESTIMAÇÃO DE PROPRIEDADES E PREVISÃO DE DEMANDA**

Trabalho de conclusão de curso apresentado ao curso de Engenharia de Energias da Universidade da Integração Internacional da Lusofonia Afro-Brasileira como requisito parcial à obtenção do título de Engenheiro de Energias.

Orientadora: Prof<sup>a</sup>. Dr<sup>a</sup>. Artemis Pessoa Guimarães.

Coorientador: Prof. Dr. Antônio Alisson Pessoa Guimarães.

**BANCA EXAMINADORA**

---

**Prof<sup>a</sup>. Dr<sup>a</sup>. Artemis Pessoa Guimarães**  
**Universidade da Integração Internacional da Lusofonia Afro-Brasileira**

---

**Prof<sup>a</sup>. Dr. Antônio Alisson Pessoa Guimarães**  
**Universidade da Integração Internacional da Lusofonia Afro-Brasileira**

---

**Prof<sup>a</sup>. Dr<sup>a</sup>. Rita Karolinny Chaves de Lima**  
**Universidade da Integração Internacional da Lusofonia Afro-Brasileira**

## **AGRADECIMENTOS**

Agradeço primeiramente a Deus, por me sustentar em todas as vezes a que recorri.

A Profa. Dra. Artemis Pessoa Guimarães amizade, pela orientação e por todo o conhecimento repassado. Por ter paciência e me ensinar com dedicação.

Ao Prof. Dr. Antônio Alisson Pessoa Guimarães pelo incentivo, pelos conselhos e por todo o conhecimento repassado sobre redes neurais artificiais.

Aos meus pais, Lucinês e Marciano por estar sempre me apoiar e incentivar nos momentos mais difíceis. A toda minha família que me aconselhou em diversos momentos.

A minha querida Vivi, pelo amor, paciência e pela parceria em toda este período.

Agradeço aos grandes amigos que conquistei durante este curso Nazareno, Brenno, Bruna, Mateus, Marisabel, Victor, Vitória e Wander. Os que mais me deram força nos momentos mais difíceis. A todos aqueles que mesmo que de passagem me ensinaram algo e me ajudaram a crescer.

Ao Grupo de Extensão e Pesquisa em Energias e Meio Ambiente – GEPEMA, que tem como responsável a Profa. Dra. Ada Amelia Sanders Lopes e Silvia Helena Dantas de Lima.

## RESUMO

O biodiesel é um biocombustível renovável, na qual é utilizado para substituir ou compor a mistura no diesel. A sua principal importância é reduzir o uso de petróleo e a emissão de CO<sub>2</sub> no meio ambiente. A comercialização do biodiesel deve atender todas as normas de qualidade determinadas pela Agência Nacional de Petróleo Gás natural e Biocombustíveis (ANP). Para que os combustíveis estejam dentro dos parâmetros de qualidade, devem ser feitos estudos das propriedades físico-químicas necessária para a comercialização, que muitas vezes são onerosos e demorados. Diante do contexto, este trabalho pretende, com o auxílio de Redes Neurais Artificiais (RNAs), abordar dois tipos de problemas distintos e independentes, ao quais estão relacionados ao biodiesel: o primeiro deles busca, com o auxílio de RNA uma Perceptron Multicamadas (PMC), estimar as propriedades de massa específica e viscosidade cinemática, levando-se em consideração para a entrada da rede a composição química de diferentes tipos de ésteres. Enquanto que no segundo problema, objetiva-se prever, por meio da RNA não-linear autorregressiva (NAR), a demanda mensal brasileira da produção de biodiesel no período entre março de 2022 a janeiro de 2028. Para tal, tomou-se como base de dados a série histórica dos volumes mensais, na qual é disponibilizada na literatura para a demanda do biodiesel. Em termos de metodologia, em ambas situações, os treinamentos das redes foram simulados mudando-se parâmetros como: o critério de parada erro quadrático médio (EQM), número de camadas ocultas e neurônios por camada. O processo de validação do modelo utilizado seguiu as etapas de treinamento e teste, cujos resultados, comparando o Erro Quadrático Médio do trabalho com os de outros autores da literatura, podem ser considerados satisfatórios tanto na predição das propriedades avaliadas, bem como na previsão da série histórica da demanda de biodiesel. Desse modo, o presente estudo destaca-se pela utilização de modelos de ferramentas computacionais, para contribuir com processos de caracterização das etapas desde as propriedades até a demanda.

**Palavras-chave:** Redes Neurais Artificiais. Viscosidade Cinemática. Massa específica. Demanda de Biodiesel.

## ABSTRACT

Biodiesel is a renewable biofuel derived from sources such as vegetable oil and animal fat, which is used to replace or compose the mixture in diesel. Its main importance is to reduce the use of oil, which is not renewable, and to contribute to the reduction of CO<sub>2</sub> emissions in the environment. To ensure the quality of biodiesel it is necessary to carry out experiments, which are often costly and time consuming. Thus, it is opted to perform a prospection of the properties using the ester data and one of the data of its physicochemical properties. Due to climate change and socioeconomic decisions, the mandatory percentage of biodiesel mixture in diesel has varied frequently, in which forecasting the demand is essential to maintain production and the decisions to be taken in the sector. In this context, this work intends, with the help of Artificial Neural Networks (ANNs), to address two types of distinct and independent problems, which are related to biodiesel: the first one seeks, with the help of a multilayer Perceptron (PMC) ANN, to estimate the properties of specific mass and kinematic viscosity, taking into account for the network input the chemical composition of different types of esters. In the second problem, the objective is to predict, with a non-linear autoregressive ANN (NAR), the demand for biodiesel production for the period between March 2022 and January 2028. For this purpose, the historical series of monthly volumes, which is available in the literature for the biodiesel demand, was taken as the data base. In terms of methodology, in both situations, the training of the networks was simulated by changing parameters such as: the stopping criterion mean square error (MSE), number of hidden layers and neurons per layer. The validation process of the model used followed the stages of training and testing, whose results, in general, can be considered satisfactory both in predicting the properties evaluated, as well as in predicting the historical series of biodiesel demand. Thus, the present study stands out for the use of computational tools models, to contribute to the processes of characterization of the steps from the properties to the demand.

**Palavras-chave:** Biodiesel. Artificial Neural Networks. Estimating properties. Demand.

## LISTA DE FIGURAS

Figura 1: Transesterificação de óleos vegetais	17
Figura 2: Porcentagem da mistura de biodiesel no diesel até 2022	24
Figura 3: RNA do tipo múltiplas camadas com backpropagation	25
Figura 4: Esquema de operação da RNA tipo NAR	26
Figura 5: Janela de operação da RNA do tipo NAR	27
Figura 6: Fase de treinamento da rede para viscosidade cinemática	31
Figura 7: Fase de teste da rede	32
Figura 8: Fase de comparação real	32
Figura 9: Fase de treinamento da rede massa específica	33
Figura 10: Fase de teste da rede	34
Figura 11: Fase de comparação real	34
Figura 12: Fase de treinamento da previsão para biodiesel até 2025	35
Figura 13: Fase de treinamento da previsão para biodiesel até 2028	35
Figura 14: Fase de teste para biodiesel até 2025	36
Figura 15: Fase de teste para biodiesel até 2028	36
Figura 16: Fase da previsão para biodiesel até 2025	37
Figura 17: Serie previsão para biodiesel até 2028	37



## **LISTA DE QUADROS**

Quadro 1: Evolução legislativa do biodiesel no Brasil até a obrigatoriedade .....	15
Quadro 2: Especificações do biodiesel B(100) e seus respectivos parâmetros .....	19

## LISTA DE TABELAS

Tabela 1: Parâmetros utilizados na rede para viscosidade cinemática a 40° mm <sup>2</sup> .s <sup>-1</sup> .....	30
Tabela 2: Parâmetros utilizados na rede para massa específica kg.m <sup>-3</sup> .....	30
Tabela 3: Parâmetros para execução da rede até 2025 .....	30
Tabela 4: Parâmetros para execução da rede até 2028 .....	30
Tabela 5: Resultados obtidos pelos autores através de diferentes métodos e redes .....	33
Tabela 6: Volume da produção de biodiesel em m <sup>3</sup> com os dados referentes a previsão até janeiro de 2025 .....	38
Tabela 7: Volume da produção de biodiesel em m <sup>3</sup> com os dados referentes a previsão até janeiro de 2028 .....	38
Tabela 8: Porcentagem dos ésteres de cada amostra e valor de suas propriedades .....	44
Tabela 9: Referência das amostras de acordo com sua numeração .....	45

## **LISTA DE SIGLAS**

ANP	Agência Nacional do Petróleo, Gás Natural e Biocombustíveis
ANVISA	Agência Nacional de Vigilância Sanitária
ARIMA	Auto Regressive Integrated Moving Average
ASTM	American Society for Testing and Materials
BFGS	Broyden-Fletcher-Goldfarb-Shanno
CEI	Comissão Executiva Interministerial
EQM	Erro Quadrático Médio
GG	Grupo Gestor
NAR	Não linear e Autoregressiva
RNA	Rede Neural Artificial

## Sumário

1 INTRODUÇÃO.....	12
2 OBJETIVOS.....	14
2.1 Objetivo Geral.....	14
2.2 Objetivos Específicos.....	14
3 REVISÃO BIBLIOGRÁFICA.....	15
3.1 História do biodiesel.....	15
3.2 Transesterificação.....	17
3.3 Matérias-primas mais utilizadas no Brasil.....	17
3.4 Composição e propriedades físico químicas.....	19
3.4.1 Massa específica $\text{kg/m}^3$ a $(20^\circ\text{C})$ .....	21
3.4.2 Viscosidade cinemática.....	22
3.5 Porcentagem obrigatória da mistura biodiesel-diesel.....	23
3.6 Redes Neurais Artificiais.....	24
3.6.1 RNA para a predição das propriedades do biodiesel.....	24
3.6.2 RNA previsão da produção de biodiesel.....	26
4 METODOLOGIA.....	29
4.1 Coleta de dados das propriedades do biodiesel.....	29
4.1.1 Coleta de dados para a previsão da demanda do biodiesel.....	29
4.2 Aplicação e processamento dos dados na RNA das propriedades do biodiesel.....	29
4.2.1 Aplicação e execução da RNA para a previsão da produção do biodiesel.....	30
5 RESULTADOS E DISCUSSÃO.....	31
5.1 Predição da Viscosidade Cinemática a $40^\circ\text{C}$ $\text{mm}^2.\text{s}^{-1}$ .....	31
5.2 Predição da massa específica $\text{kg.m}^{-3}$ .....	33
5.3 Processamento e execução da rede com os dados de produção do biodiesel.....	34
5.4 Previsão da produção do biodiesel.....	35
6 CONCLUSÃO.....	39
7 REFERÊNCIAS.....	40
APÊNDICE A – DADOS UTILIZADOS NA RNA DO TIPO FEEDFORWARD MULTICAMADAS.....	44

## 1 INTRODUÇÃO

O biodiesel é um combustível proveniente de fontes renováveis e menos emissor de CO<sub>2</sub> do que o diesel. Podendo ser produzido por três formas diferentes microemulsões, craqueamento e transesterificação que é utilizada em escala comercial, sua produção deriva da reação dos triglicerídeos presentes em gorduras de animais e óleos vegetais, que reagem com um álcool, seja etanol ou metanol, gerando ésteres e glicerina (RINALDI *et al.*, 2007). A maior produção de biodiesel no Brasil deriva da semente de soja, entretanto depender apenas da produção de uma matéria prima pode ocasionar sérios problemas caso sua produção seja afetada por algum fator biológico ou climático. Para produzir o combustível a partir de novos insumos é necessário saber se o produto atenderá as exigências das normas da Agência Nacional de Petróleo, Gás Natural e Biocombustíveis (ANP). Realizar todos os testes de qualidade para um novo produto tem custo elevado, desse modo opta-se por estimar algumas das propriedades por meio dos testes menos onerosos e fazer uma estimativa previa com os resultados (RAMOS, 2017; LOBO e FERREIRA 2009).

No Brasil, o biodiesel vem se destacando desde o ano 2005, com a criação do Programa Nacional de Produção e Uso de Biodiesel (PNPD). Esse programa interministerial do Governo Federal foi lançado no ano de 2005, tendo como objetivo a implementação de forma sustentável, tanto técnica, como economicamente, da produção e uso do biodiesel, com enfoque na inclusão social e no desenvolvimento regional. A obrigatoriedade da mistura de biodiesel no diesel (Bx) foi introduzida pela Lei Federal de nº 11.097, de janeiro de 2008 em 2%. O crescimento da demanda brasileira de biodiesel, foi através da porcentagem da mistura que aumentou gradativamente, chegando em até 13% no período de março de 2021 (ANP, 2022; GOV, 2020).

Desse modo há procura de matérias primas eficientes, que apresente todos os requisitos de qualidade do biodiesel. Como custo elevado para alguns dos testes de qualidade, faz necessário prever a qualidade através de programas computacionais. Utilizando apenas os dados de ésteres e uma propriedade de fácil obtenção dos seus resultados como a viscosidade cinemática, pode ser estimado um panorama geral aproximado das propriedades subjacentes (SOUZA, 2015).

Conhecer a demanda do biodiesel no Brasil auxilia as decisões a serem tomadas no setor. Esse conhecimento ajuda na criação de estratégias, com a finalidade de assegurar a disponibilidade das matérias-primas utilizadas no processo de produção, além da conciliação com as exportações de algumas das oleaginosas utilizadas na produção, como a soja. Também traz a importância da preocupação ambiental relacionada ao aumento das emissões de CO<sub>2</sub>, que

pode ser intensificado, caso haja alta do consumo de diesel derivado do petróleo no país. Prever o volume futuro de biodiesel a ser utilizado é essencial para manter o balanço nacional econômico e evitar o déficit na capacidade de produção, assegurando o equilíbrio na mistura (CAIRES e SIMONELLI, 2021).

As Redes Neurais Artificiais (RNAs) são sistemas artificiais que trabalham semelhantes ao sistema biológico neural dos seres vivos, as quais foram projetadas para receber várias informações de entrada. Em seguida, processa tais informações, a partir das unidades de processamento e conexões sinápticas, até que aprenda por experiência. A comparação passa por uma equação, que determina o erro quadrático médio e conclui a aprendizagem através desses erros e acertos. O treinamento das RNAs ajusta esses pesos, para quando comparados, o erro seja próximo ou menor o suficiente do que o determinado no critério de parada. No entanto, faz-se necessário a aquisição de um banco que consiga conter uma quantidade de objetos que seja considerada plausível para a extração de conhecimento. Dependendo do tipo de problema, a resposta da rede poder ser uma estimação de alguma propriedade em estudo ou a previsão futura de série temporal (SILVA e FLAUZINO, 2016; NASCIMENTO *et al.*, 2000).

O modelo Auto Regressive Integrated Moving Average (ARIMA), comumente utilizado em estatísticas e series temporais compõe-se de ciclos interativos, que identifica, estima e diagnostica as previsões. Esses modelos podem ser explicados através da relação entre os valores reais no passado e a função da RNA que gerará pesos sinápticos e é utilizado para prever o valor atual (PÉREZ, 2022).

Dessa forma o trabalho utilizou das ferramentas computacionais para prever, analisar e discutir as etapas de predição das propriedades e previsão da demanda do biodiesel. Os modelos obtidos, têm potencial para serem aplicados em diferentes cenários, desde políticos até privados. O intuito é auxiliar desde o controle da qualidade do biocombustível, até a etapa de vendas, além de contribuir com o meio ambiente, já que sua combustão emite menos CO<sub>2</sub> do que o diesel derivado do petróleo.

As redes utilizadas foram escolhidas devido a serem mais adequadas para os dados de entradas e a necessidade da resposta de saída. A rede do tipo feedforward multicamadas com realimentação (backpropagation), foi utilizada pois necessitava que a rede entrasse com os ésteres e fizesse a comparação com as propriedades de cada amostra, resultando em uma saída única informando os pesos sinápticos. Já a rede do tipo não linear e autoregressiva (NAR), foi escolhida pois utiliza de uma série histórica existente e realiza a previsão.

## 2 OBJETIVOS

### 2.1 Objetivo Geral

O presente trabalho tem como objetivo principal utilizar as Redes Neurais Artificiais (RNA) no estudo do biodiesel em dois cenários distintos. Predizer as propriedades do biodiesel, a partir de sua composição química e prever a demanda brasileira para os próximos anos (até 2028).

### 2.2 Objetivos Específicos

- Desenvolver uma Rede Neural Artificial (RNA) que possibilite montar uma matriz de pesos sinápticos através da comparação da porcentagem de ésteres e as propriedades do biodiesel.
- Executar a rede para estimar duas propriedades diferentes:
  - ✓ Viscosidade cinemática
  - ✓ Massa específica
- Desenvolver uma Rede Neural Artificial (RNA) que atenda aos requisitos dos dados de entrada para prever a demanda de biodiesel no mercado brasileiro, em distintos cenários.
  - ✓ De março de 2022 até janeiro de 2025
  - ✓ De março de 2022 até janeiro de 2028

### 3 REVISÃO BIBLIOGRÁFICA

#### 3.1 História do biodiesel

O início do consumo em larga escala de um combustível ocorreu no século XVIII, constituía-se do carvão. Com algum tempo surgiu a descoberta do petróleo e gás natural. Alguns estudos voltados ao impacto no meio ambiente ocasionados pelo uso destas fontes energéticas, apontam a necessidade de alternativas menos poluentes, desse modo o biodiesel vem ganhando espaço devido ser proveniente de matérias primas renováveis, como as gorduras animais e óleos extraídos de sementes (PINHO; TEIXEIRA, 2005).

Em 1900, o engenheiro mecânico franco-alemão Rudolf Christian Karl Diesel, apresentou na Exposição Universal de Paris o primeiro protótipo de um motor movido a biodiesel. O motor a injeção indireta utilizava como combustível o óleo de amendoim e devido a sua queima ineficiente, além da alta viscosidade, ocasionou a oclusão da passagem do fluido nos seus bicos (MARTINS; CARVALHO, 2007).

Em 1937 o Dr. George Chavanne, cientista da Universidade de Bruxelas na Bélgica, patenteou o processo químico chamado de transesterificação. O processo mostrou eficácia e logo ganhou notoriedade quando aplicado na produção do biodiesel. O biocombustível passou a ser utilizado comercialmente em motores a diesel em 1938, na qual um ônibus fazia a rota levando passageiros da cidade de Bruxelas a Lovaina. A segunda guerra mundial necessitou de combustíveis para locomoção dos veículos e o biodiesel foi utilizado comercialmente nas “frotas de guerra”. O primeiro pedido de patente no Brasil ocorreu em 1980 pelo Dr. Expedito José de Sá Parente em Fortaleza-CE (KNOTHE, 2006).

O Quadro 1 mostra os principais passos realizados na legislação brasileira, desde o início da regulamentação até a obrigatoriedade da mistura de biodiesel no diesel.

Quadro 1: Evolução legislativa do biodiesel no Brasil até a obrigatoriedade

2003	Agência Nacional do Petróleo (ANP) lança portaria nº 08/2003 240 que inicia o estabelecimento da regulamentação para a utilização de combustíveis sólidos, líquidos ou gasosos não especificados no País.
------	-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------



	<p>Governo Federal emite Decreto nº12/2003 que nomeia a Comissão Executiva Interministerial (CEI) e o Grupo Gestor (GG), como encarregados de implantar ações para a produção e uso do biodiesel.</p>
2004	<p>As resoluções 41 e 42 da ANP de 24/11/2004, sinaliza a obrigatoriedade de utilização da produção do biodiesel misturado com o diesel, cuja proporção é de 2%.</p> <p>Governo federal lança o programa de produção de uso do biodiesel em 06/12.</p>
2005	<p>Autorização da Lei 11.097 de 13/01/2005 que aprova a introdução do biodiesel na matriz energética brasileira, de modo a comercialização tornar-se voluntária.</p> <p>Em 24/03/2005 é inaugurada em Belo Horizonte-MG a primeira usina de biodiesel no Brasil.</p> <p>sanção do presidente a medida provisória em 19/04/2005.</p>
2006	<p>Brasil inicia a exportação da tecnologia dos biocombustíveis para a Europa.</p> <p>Volkswagen inicia os testes em 5% de biodiesel nos caminhões.</p>
2008	<p>Em janeiro de 2008, entrou em vigor a mistura legalmente obrigatória de 2% (B2), em todo o território nacional.</p>

Fonte: Adaptado de GOV(2019); ANP (2022).


O Programa Nacional de Produção e Uso de Biodiesel (2013) adotou uma definição como “O biodiesel é um combustível biodegradável derivado de fontes renováveis, que pode ser produzido a partir de gorduras animais ou de óleos vegetais, [...] no Brasil que podem serem utilizadas, tais como mamona, dendê, girassol, canola, gergelim, soja, dentre outras”. O biodiesel pode ser obtido de três formas microemulsões, craqueamento e a transesterificação que é o método mais eficiente, melhor custo benefício e mais fácil de realizar (MALESKI, 2018). Em termos químicos é definido como uma cadeia de ésteres de ácidos graxos que pode ser produzido através da reação por transesterificação de óleos vegetais ou gordura de animais (SCHUCHARDT; SERCHELI; VARGAS, 1998).

### 3.2 Transesterificação

Ésteres graxos produzidos através de transesterificação são os insumos básicos para uma ampla gama de derivados oleoquímicos com alto valor agregado. Os ésteres monoalquílicos podem ser utilizados na produção de lubrificantes, polímeros, plastificantes, produtos de higiene pessoal, papéis, tecidos, alimentos e biocombustíveis (GARCIA, 2006).

A produção do biodiesel a partir de óleos vegetais por transesterificação representado na Figura 1 consiste na reação de um mol de triacilglicerídeo com três mols de um álcool composto de cadeia curta (metanol ou etanol), na presença de um ácido forte ou base, formando além do ésteres alquílicos de ácidos graxos (biodiesel) o glicerol (SCHUCHARDT; SERCHELI; VARGAS, 1998). Dependendo do álcool utilizado podemos chamar a reação de metanólise ou etanólise respectivamente (MARCINIUK, 2007).

Figura 1: Transesterificação de óleos vegetais



Fonte: (SCHUCHARDT; SERCHELI; VARGAS, 1998).

O processo em geral consiste em três reações sequenciais consecutivas e reversíveis, onde ocorre uma formação intermediária de monoglicerídeos. A separação de suas fases com o glicerol formado pela reação é feita através da inclusão de álcool saturando a reação e forçando a separação de suas fases. Diversos fatores podem alterar a reação de transesterificação, tais como o tipo de catalisador podendo ser alcalino ou ácido, temperatura, razão molar de álcool por óleo vegetal, quantidade de água contida nos reagentes e a gordura livre de ácido (SCHUCHARDT; SERCHELI; VARGAS, 1998).

### 3.3 Matérias-primas mais utilizadas no Brasil

Os óleos vegetais e as gorduras animais são lipídeos insolúvel em água além de existir uma classe microbiana rica em lipídeos. De acordo com a resolução-rdc nº 270, de 22 de setembro de 2005 da Agência Nacional de Vigilância Sanitária (ANVISA), a definição técnica

que diferencia a gordura do óleo é que em uma temperatura a 25°C o óleo apresenta-se no estado líquido e a gordura na mesma temperatura estará no estado sólido.

Os ácidos orgânicos lineares conhecidos como ácidos graxos são compostos por cadeia carbônica, pode ter a presença de ligações duplas entre os átomos de carbono (insaturação) ou sem ligação dupla (saturados). Os ácidos insaturados podem gerar isômeros do tipo *cis* ou *trans*. Os óleos e gorduras estão presente em todas as formas vivas de plantas e animais da natureza, porém a quantidade varia de em cada espécie. Para que sua exploração seja rentável e comerciável, precisamos de espécies que tenha em sua composição a capacidade de produzir alta porcentagem de lipídeos (RAMOS *et al.*, 2017).

O Brasil tem uma vasta extensão territorial e produz diversas cultivares, na qual as espécies plantadas tem grande porcentagem de óleo em sua estrutura, tais são o óleo da soja, o óleo de algodão, de palma, de amendoim, de nabo-forrageiro, de girassol, de mamona, de sésamo, do pinhão-manso, do babaçu, do buriti, do dendê e da macaúba. A agropecuária também é predominante e como grandes exportadores de carne, parte da gordura animal é destinada para a produção do biodiesel. Por fim os óleos e gorduras utilizadas em frituras e cocções de alimentos também são utilizados como matéria-prima (PINHO, TEIXEIRA, 2005; RAMOS *et al.*, 2017).

O procedimento da reutilização de gorduras e óleos usados no preparo de frituras de alimentos, para agregar a matéria prima do combustível traz consigo relativas consequências, pois a introdução de frituras sob imersão permite que haja reações hidrolíticas, acarretando assim uma aceleração na oxidação e aumentando a temperatura causando mudanças físico química e organolépticas do óleo. Quanto maior a quantidade de insaturações, maior a tendência à oxidação levando à formação de compostos como ácidos, aldeídos, ésteres, cetonas, peróxidos, hidroperóxidos, álcoois e compostos alifáticos, assim como à tendência de polimerização com a formação de dímeros e trímeros (RAMOS *et al.*, 2017).

Dependendo do tipo de matéria prima utilizada para a produção do biodiesel, as características físicas e químicas mudam, de modo a associar-se a qualidade e rendimento do combustível como produto final.

### 3.4 Composição e propriedades físico químicas

O combustível pode sofrer variância em sua qualidade devido a influência de componentes que estão presentes, fatores como o manejo inadequado no transporte, armazenagem e impurezas na fabricação, dentre outras, pode alterar a qualidade da substância.

As características da composição do biodiesel mudam de acordo com o tipo da matéria prima, desse modo algumas especificações devem ser seguidas. Caso o produto não se enquadre nas especificações do regulamento é vedada qualquer tipo de comercialização do mesmo. As análises são realizadas pelo distribuidor e os resultados são emitidos através de um boletim de conformidade (documento de qualidade). A resolução da ANP determina de parâmetros tabelados para que o distribuidor faça as análises das seguintes características “aspecto, cor visual, ponto de fulgor, massa específica, condutividade elétrica, número de acidez e teor de água, com indicação dos métodos empregados e os respectivos limites constantes da especificação” (ANP, 2021).

O biodiesel é uma mistura de ésteres de ácido graxo compostos por hidrocarbonetos e oxigenados, dessa forma sua composição assemelha-se ao do diesel. Os ácidos orgânicos denominados de graxos, tem presença de insaturações e diferem do número de carbonos que constitui sua cadeia. Existe diversos tipos de ácidos, porém a literatura lista alguns como os mais importantes, cujo sua concentração é maior na matéria prima do biodiesel. Os principais ácidos graxos conhecidos na natureza são láurico C12:0, palmítico C16:0, palmitoleico C:16:1, esteárico C18:0, oléico C18:1, linoléico C18:2 e linolênico C18:3. O que difere de um biodiesel a outro é a porcentagem de ésteres, juntamente com suas respectivas propriedades. Alguns fatores externos podem-no alterar, tais como temperatura, acidez da matéria prima, impurezas e presença de água (Oliveira *et al.*, 2007).

O Quadro 2 foi adaptado para mostrar as especificações com a faixa de limite permitida de acordo com cada propriedade analisada e os aspectos característicos físicos que são afetados devido a diversos fatores.

Quadro 2: Especificações do biodiesel B(100) e seus respectivos parâmetros

CARACTERÍSTICA	LIMITE	FUNÇÃO/IMPORTÂNCIA DO PARÂMETRO
Aspecto	Límpido e isento de	Funciona como alerta visual de contaminações e podem ser por outros parâmetros da especificação. Por meio da análise visual preliminar, é possível verificar a presença de impurezas, como materiais em

	impurezas	suspensão e turbidez, que podem ser decorrentes da presença de água, por exemplo.
Massa Específica (20°C)	850 a 900 kg/m <sup>3</sup>	Interferi na relação de ar/combustível na proporção ideal injetados na câmara de combustão, desse modo afeta diretamente o desempenho do motor. A propriedade estabelece a massa por unidade de volume de uma substância a uma temperatura de 20°C. Os motores de injeção de diesel B utilizam o combustível razão volumétrica, e é fundamental propriedade não sofra grandes alterações para não comprometer a eficiência do motor.
Viscosidade a 40°C	3,0 a 6,0 mm <sup>2</sup> /s	Este parâmetro influencia diretamente no processo de queima na câmara de combustão. O biodiesel geralmente costuma apresentar a viscosidade superior à do diesel A. A viscosidade alta pode ocasionar maior esforço da bomba injetora e provocar má alimentação de combustível e ocorre a redução da eficiência na atomização pelos bicos injetores na câmara de combustão e acúmulo de resíduos. Já a viscosidade baixa, pode gerar vazamentos no sistema de alimentação.
Enxofre, máx.	10 mg/kg	O enxofre se lançado em grande volume pode afetar o meio ambiente (em termos de emissões) e o motor. Emissões: na queima do enxofre é convertido para dióxido de enxofre, sendo uma substância altamente poluente ao meio ambiente na forma de óxido e sendo um dos gases que combinados formam chuva ácida. Tem como benefício contribuir para formação de material particulado, devido o enxofre ser um iniciante da formação de partículas.
Ponto de fulgor, °C, mín.	100 °C	Responsável pela segurança do transporte e manuseio do combustível. A definição do ponto de fulgor se dá como a menor temperatura corrigida a pressão de 101,3kPa (760mmHg). Ou seja, se um combustível libera vapor o suficiente para causar ignição por uma fonte externa de calor. Como o motor a diesel trabalha com taxa de compressão ele precisa que o combustível tenha o ponto certo de ignição para que não haja a queima antes do tempo certo.

Índice de acidez, máx.	0,50 KOH/g	A oxidação do biodiesel gera acidez, logo se o combustível está degradado, o nível de acidez será elevado. Os ácidos são um indicativo de deterioração do produto e no motor pode levar a corrosão das peças metálicas.
Teor de éster, mín.	96,5 % massa	Está relacionado com a pureza do biodiesel, quanto maior o teor de éster menor será a concentração de produtos indesejáveis como ácidos graxos livres, álcool residual, glicerina e água. Se o teor for mais baixo que o especificado reduzirá a eficiência de combustão nos motores.
Estabilidade à oxidação a 110 °C, mín.	12 h	Indicativa a estabilidade de oxidação do biodiesel, que evolui com o tempo. A estabilidade é influenciada pelo grau de insaturação do biodiesel e a posição das duplas ligações na cadeia carbônica. As insaturações favorecem reações de oxidação dos ésteres, que pode formar produtos ocasionando a formação de sedimentos e obstruir o sistema de injeção de combustível.

Fonte: Adaptado de NOTA TÉCNICA Nº 10/2021/SBQ-CPT-CQC/SBQ/ANP-DF.

### 3.4.1 Massa específica kg/m<sup>3</sup> a (20°C)

Na engenharia é de fundamental importância o estudo da densidade, que é aplicado em inúmeras situações. Na indústria dos combustíveis, a densidade sem função da temperatura é usada no cálculo de projeção dos reatores, sistemas de destilação, projeção dos tanques de estocagem e no transporte em todas as etapas do combustível desde a matéria prima ao consumidor (VENY, 2009).

As propriedades dos combustíveis devem ser estudadas, para que observe o comportamento das reações sobre cada circunstância incididas sobre o funcionamento do motor. Para a análise da massa específica em condições de temperatura ambiente e pressão atmosférica calcula-se através da razão da massa do fluido pelo seu volume Equação 1 (COIMBRA, 2015).

$$\rho = \frac{m}{V} \quad (\text{Equação 1})$$

Um dos principais parâmetros do estudo do biodiesel no estágio de queima no motor é a massa específica com relação da temperatura, cuja está relacionada diretamente ao sistema de injeção e combustão nos motores. A pressão, temperatura, matéria prima utilizada no combustível e a rota utilizada na produção tem influência direta na massa específica, desse modo o estudo dessa propriedade é fundamental. A massa específica é dada pela unidade no [S.I] em  $\text{kg.m}^{-3}$  e a Equação 2 trabalha com a temperatura em K e os parâmetros da modelagem são os  $a_i$ . Vale observar a relação da temperatura que é diretamente proporcional a massa relação entre a massa específica do biodiesel, e suas misturas BX, com a temperatura (AZEVEDO *et al.*, 2020a).

$$\rho(T) = a_1 + a_2T \quad (\text{Equação 2})$$

A massa específica influencia várias características do biodiesel como o número de cetano, razão de ar/combustível ideal na câmara de combustão, pulverização na câmara e pressão da injeção. Caso não esteja dentro dos parâmetros estabelecidos, irá afetar diretamente o desempenho do motor, já que a alta densidade não ocasiona a queima total gerando material particulado e fumaça (CAVALCANTE, 2010).

### 3.4.2 Viscosidade cinemática

A viscosidade do biodiesel é resultante de elementos físicos químicos, que constituem de sua matéria de origem e dependendo da porcentagem presente de cada ácido graxo fará variar a composição do biocombustível que conseqüentemente suas propriedades. A alta viscosidade é uma das principais propriedades a ser estudada, pois afeta diretamente o funcionamento do sistema de injeção, levando o problema para a bomba de combustível, o processo de compressão e combustão, além de depositar partículas no sistema durante a injeção do combustível na câmara (PRABU, 2013).

Outros métodos envolvendo a temperatura e a pressão são utilizados para estudar o comportamento da viscosidade do fluido levando em consideração determinados fatores. Vários métodos podem ser aplicados como a Equação 3 de Andrade. Essa equação tem o comportamento não linear por tratar-se de ser exponencial relacionando a viscosidade cinemática com a temperatura. Podemos ver que a análise se torna difícil, pois deve ser

analisada em diferentes estágios e temperaturas. Varia de temperaturas negativas, no caso da temperatura ambiente nas regiões extremamente frias, a altas temperaturas ocasionadas pela queima do combustível no motor (AZEVEDO *et al.*, 2020b).

$$v = a_1 * \exp\left(\frac{a_2}{T}\right) \quad (\text{Equação 3})$$

$v$  = Viscosidade cinemática em  $\text{m}^2.\text{s}^{-1}$ ;

$T$  = Temperatura em K;

$a_i$  = Parâmetros do modelo.

### 3.5 Porcentagem obrigatória da mistura biodiesel-diesel

Em 2005 foi elaborada a primeira lei nº 11.097, de 13 de janeiro de 2005 que determina a obrigatoriedade da mistura a partir de 2008 e é reconhecida por Bx, na qual o x representa a quantidade da porcentagem do biodiesel a ser misturada no diesel. E o define como um combustível renovável oriundo da biomassa para utilização em motores por compressão, com a finalidade de substituir ou misturar parcialmente o óleo diesel. A partir da primeira resolução foram realizadas mudanças frequentes com intervalos na média de um ano até o ano de 2021, precedido pela pandemia da covid 19 (ANP, 2014b).

A porcentagem obrigatória da mistura de biodiesel no diesel cresceu até 2021, porém teve uma estagnação do aumento da porcentagem devido agravantes ocasionados pela a pandemia. A mão de obra nas principais produções de óleos e gorduras reduziu e afetou a produção do biodiesel. A produção não supria a necessidade demandada e conseqüentemente elevaria o valor do combustível parcial e final, desse modo houve uma redução considerável passando de 13% para 10% (BIODIESELBR, 2021). A Figura 2 mostra a porcentagem obrigatória a cada alteração desde 2005 que a mistura era facultativa até o presente momento 2022.



Figura 2: Porcentagem da mistura de biodiesel no diesel até 2022



Fonte: Autor (dados da ANP).

### 3.6 Redes Neurais Artificiais

As RNAs têm diversas funções de aplicação, utilizadas mundialmente nos principais setores de tecnologia, com grande incidência nas áreas de de estimação de valores e previsão de séries históricas. Tal ferramenta está inserida na área de inteligência computacional e tem a capacidade de processamento paralelo, a partir das unidades de processamentos e das conexões sinápticas, as quais são atribuídos pesos no processamento de aprendizagem da informação (pesos sinápticos). Em linhas gerais, o processo de aprendizagem em algoritmos supervisionados é baseado por correção de erros. Especificamente, a rede é treinada com um conjunto de dados de entrada, em cada amostra possui um rótulo (que pode ser um valor numérico ou uma classe), o qual é denominado de saída desejada. Então, quando a base de dados é apresentada, a rede retorna um conjunto de valores de saída em que é comparado ao conjunto dos valores de saída desejado (conjunto dos rótulos) (SILVA, 2016).

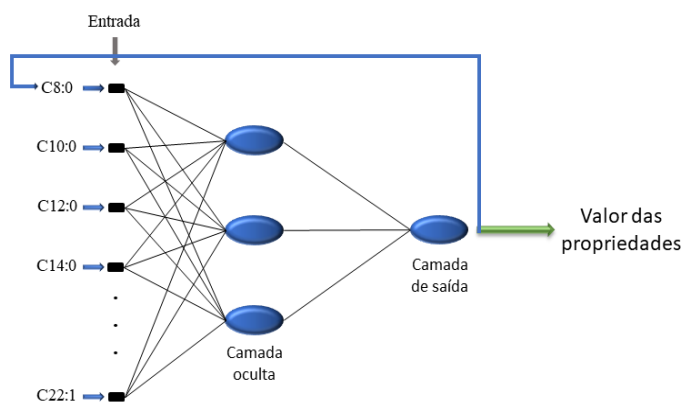
#### 3.6.1 RNA para a predição das propriedades do biodiesel

Para criar uma matriz de pesos sinápticos que possa ser utilizada em um simulador capaz de estimar a qualidade do biodiesel, necessitou de uma rede que gerasse os pesos através da porcentagem de ésteres relacionando com as propriedades reais e simuladas. Para satisfazer essa necessidade trabalhou-se com uma Rede Neural Artificial (RNA) do tipo *feedforward* multicamadas com processo de aprendizagem *backpropagation* (JAHIRUL *et al.*, 2019).

As RNAs do tipo feedforward multicamadas são comumente encontradas na literatura em problemas de estimação de valores devido a disposição de seus conjuntos de neurônios em uma ou mais camadas e os dados incididos sempre trabalham em direção a camada de saída. A Figura 3 apresenta a ilustração da construção da RNA com realimentação (backpropagation), com as camadas de entrada, uma camada intermediária possuindo três neurônios (denominada de camada oculta) e uma camada de saída (RAMOS, 2003; ARANCIBIA, 2008).

Os dados de entrada da rede são a porcentagem de cada ésteres que compõe a amostra. Para melhor entendimento a Figura 3 demonstra que os valores da porcentagem entram em cada caixinha, por exemplo se na amostra 01 se o éster C8:0 tiver 0.25, será esse valor que entrará na primeira caixinha da rede, o valor de C10:0 entrará na segunda e assim sucessivamente. Os ésteres que não tem informação, é preenchido com 0, para não ocasionar erro de incoerência dos dados. A medida que os dados vão entrando em cada neurônio a rede adota pesos sinápticos que irá compor a matriz de saída desejada e calcular o resultado de saída da rede.

Figura 3: RNA do tipo múltiplas camadas com backpropagation



Fonte: Autor.

Para validar o resultado e saber que a rede adotou os pesos certos, ela utiliza a função do Erro Quadrático Médio EQM, na qual matematicamente através da equação abaixo ela verifica se o resultado obtido ( $Z_i$ ) foi próximo o suficiente do valor real ( $Y_i$ ) da propriedade a ser analisada. Caso seu resultado seja baixo a rede valida a saída, caso não seja, a função backpropagation (objetiva minimizar o erro quadrático médio) retorna o valor de saída para a entrada e a rede utiliza o que aprendeu para rodar novamente.

$$MSE = \frac{1}{n} \sum_{i=1}^n (Z_i - Y_i)^2 \quad (\text{Equação 4})$$

Por fim cada EQM é salvo e realizado uma operação na qual o ultimo resultado subtrai com o seu antecessor. A rede gera um valor que é comparado com o critério determinado

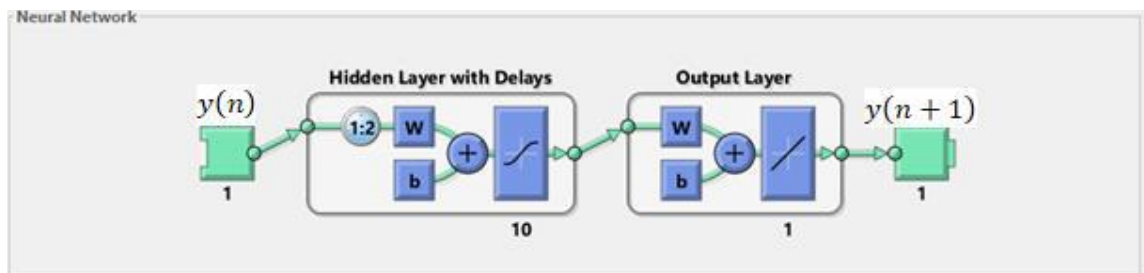
digitando o quão pequena deverá ser a diferença. Se a diferença for menor do que  $10^{-x}$  na qual  $x$  é um valor determinado, a rede para a execução. Caso a rede chegue na seguinte execução EQM1, EQM2, ... , EQM1000 e foi determinado que o critério de parada será de  $10^{-3}$  a rede para na validação da condição mostrada na Equação 5.

$$EQM1000 - EQM999, \leq \text{que } 10^{-3} \quad (\text{Equação 5})$$

### 3.6.2 RNA previsão da produção de biodiesel

A produção de biodiesel tende a variar mensalmente, desse modo objetivou-se duas previsões da produção sendo uma até 2025 e outra até 2028. A RNA utilizada na previsão foi do tipo NAR, feedforward multicamadas supervisionada, não linear e autoregressiva. Para abordar de forma satisfatória o problema de previsão de séries histórica, adotou-se uma RNA do tipo não-linear autoregressiva (NAR). Esta é também uma rede multicamadas feedforward, cujo algoritmo de aprendizagem é supervisionado e tendo-se como variáveis de entrada os valores da série histórica. No entanto, tem-se o seguinte funcionamento, o qual é esquematizado na Figura 4 (SILVA, SPATTI e FLAUZINO, 2016).

Figura 4: Esquema de operação da RNA tipo NAR

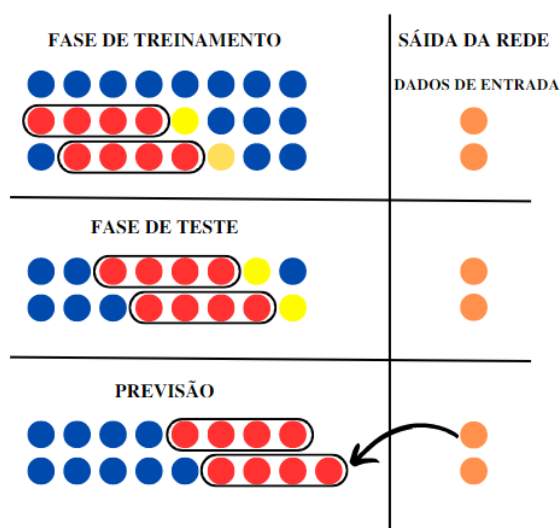


Fonte: Adaptado de Demuth et al., 2015.

Para melhor entendimento analisando a Figura 5, considere uma série temporal com 8 valores (representados nas bolas azuis), sendo que das 8 escolheremos as 6 primeiras para treinar a rede. Em seguida, faz-se necessário definir o tamanho da janela de previsão ou a ordem do preditor, cujo tamanho indica a quantidade de dados passados que serão utilizados para prever o próximo valor da série histórica. A ordem do preditor também indica a quantidade de variáveis de entrada que a rede processará. No nosso caso, definiu-se uma janela de tamanho 4, as quais estão destacadas na cor vermelha. Noutros termos, inicialmente, são as quatro primeira bolas da série histórica, o objetivo do algoritmo é prever a quinta bola (em amarelo) que está fora da janela retangular. Naturalmente, a rede produz uma saída (bola

na cor laranja), a qual é comparada com a saída desejada (a bola na cor amarela) e o valor do erro na comparação é armazenado.

Figura 5: Janela de operação da RNA do tipo NAR



Fonte: Adaptado de (SILVA; GUIMARÃES, 2021).

Dando prosseguimento ao algoritmo, a janela desliza de uma unidade à direita, tomando-se como variáveis de entrada as próximas 4 amostras da série temporal, com propósito de prever a sexta amostra da série (a bola amarela fora da janela retangular). De forma semelhante, será realizado um comparativo entre a saída obtida pela rede e a saída desejada. Considerando as seis primeira amostras, este processo é então repetido até que o EQM seja minimizado. Uma vez tendo-se a RNA treinada, vem a fase de teste, que funciona, basicamente, como um simulador, no processo de previsão. No caso, a rede irá fazer a previsão de dois valores futuros, que serão comparados com as amostras 7 e 8 restantes. A janela de previsão inicia com deslizamento de uma unidade à direita, dada em relação à última janela obtida da fase de treinamento e encerra até fazer a previsão da última amostra da série. Nesta fase, o algoritmo não mais atualiza os pesos sinápticos, apenas compara os resultados das saídas obtidas (bolas amarela) com as desejadas (bolas laranjas) em termos do EQM. Se a taxa de erro for considerada aceitável, valida-se momentaneamente o modelo.

Por fim, com o modelo validado, entra-se efetivamente no processo de previsão temporal. Nesta etapa, não mais será realizado o processo de comparação. Além disso, deve-se a priori definir o horizonte de previsão. No nosso caso, iremos prever um horizonte de tamanho 2, ou seja, faremos a previsão duas amostras à frente da série histórica. Então, tomando-se as 4

últimas amostras da série, a RNA irá prever, como resposta ao sistema, uma bola na cor laranja, tendo-se a primeira previsão obtida. Em seguida, a janela é deslizada, novamente, uma unidade à direita. Tomando-se, assim, as últimas 3 amostras da série histórica acrescida do último valor efetivamente previsto, tem-se um novo valor de previsão gerado pela rede (uma nova bola laranja), o qual conclui o processo.

## 4 METODOLOGIA

### 4.1 Coleta de dados das propriedades do biodiesel

A base de dados foi construída a partir de informações sobre a composição química de diferentes tipos de matéria prima do biodiesel, bem como resultados das análises de massa específica e viscosidade cinemática para cada uma das amostras. As amostras foram coletadas em diversos sites de revistas científicas e fontes internacionais. A pesquisa objetivou artigos, revistas, monografias e teses, na qual tivessem todos os dados de ésteres apresentados, assim como suas propriedades físico-químicas.

Para a predição foi coletado as informações das porcentagens dos ésteres que tenha o valor das propriedades disponíveis. Devido a baixa informação literária, na qual alguns trabalhos tinham apenas os ésteres e outros apenas as propriedades só foi possível coletar 38 amostras com as informações necessárias para a execução da rede, na qual as 38 tinha os valores da massa específica e apenas 34 teve os valores da viscosidade cinemática.

#### 4.1.1 Coleta de dados para a previsão da demanda do biodiesel

Através do acervo literário foi possível obter trabalhos de revistas acadêmicas, teses, artigos, tabelas, gráficos e conteúdo, que auxiliaram na pesquisa. Contudo, a informação do volume da demanda do biodiesel foi obtida no site da Agência Nacional do Petróleo, Gás Natural e Biocombustíveis (ANP), que está em convênio com o sistema do governo. Para a previsão foi utilizada na rede 172 meses, desde janeiro de 2008 à março de 2022, referente aos dados disponibilizados pela (ANP, 2022) até o momento da execução da rede.

### 4.2 Aplicação e processamento dos dados na RNA das propriedades do biodiesel

Tendo-se como variáveis de entrada os ésteres supracitados, a RNA do tipo PMC com aprendizado supervisionado foi executada para prever duas propriedades distintas do biodiesel no caso: massa específica e viscosidade cinemática. Além disso, configurou-se a rede para que houvesse uma única saída. Desta forma, as estimações das propriedades foram tratadas de maneiras independentes ou em duas simulações distintas. Definiu-se, portanto, uma topologia de rede para cada situação e com critério de parada baseado na diferença entre dois erros quadráticos médios em duas épocas consecutivas.

As topologias de rede com os respectivos parâmetros estão descritas nas Tabelas 1 e 2.

Tabela 1: Parâmetros utilizados na rede para viscosidade cinemática a 40° mm<sup>2</sup>.s<sup>-1</sup>

Parâmetros	Dados
Erro Quadrático Médio (EQM)	-11
Números de camadas ocultas	2
Quant. de amostras utilizadas	34
Quant. de neurônio por camada	6 e 6

Fonte: Autor.

Tabela 2: Parâmetros utilizados na rede para massa específica kg.m<sup>-3</sup>

Parâmetros	Dados
Erro Quadrático Médio (EQM)	-10
Números de camadas ocultas	1
Quant. de amostras utilizadas	38
Quant. de neurônio por camada	5

Fonte: Autor.

A função sementes utilizada nas duas redes, servirá para fixa os dados, caso contrário a semente seja aleatoriamente escolhida pela rede, toda vez que rodar ela mostrará um novo resultado, mesmo sendo com os mesmos parâmetros. Por fim as sementes foram digitadas manualmente, sempre mudando-as quando as análises gráficas visuais não eram satisfatórias.

#### 4.2.1 Aplicação e execução da RNA para a previsão da produção do biodiesel

A execução foi realizada em duas etapas para a produção do biodiesel, ambas para os anos de 2025 e 2028.

Com 137 meses destinados ao treinamento, ou seja, 80% dos dados disponíveis, permitiu-se utilizar para a ordem do preditor entre 90 a 100 meses. Significa dizer que para a previsão até 2025 a RNA do tipo NAR será constitua de 100 entradas, tendo-se uma janela deslizante de 100 meses para prever o mês subsequente. Em sequência os 20% dos dados restantes servirá para comparar a previsão da rede com os dados existentes, caso a diferença dos resultados seja menor do que o determinado no Erro Quadrático Médio EQM, válida momentaneamente os pesos sinápticos adotados. Por fim, com os pesos validados, a RNA preverá a demanda mensal do volume de biodiesel em m<sup>3</sup>.

Os parâmetros que geraram os melhores resultados para o biodiesel estão apresentados nas Tabelas 3 e 4.

Tabela 3: Parâmetros para execução da rede até 2025

Parâmetros	Valores
Ordem do preditor	100
Número de passos a frente	34
Número de camadas ocultas	1
Número de neurônios em cada camada	9
EQM	-11

Fonte: Autor.

Tabela 4: Parâmetros para execução da rede até 2028

Parâmetros	Valores
Ordem do preditor	90
Número de passos a frente	69
Número de camadas ocultas	2
Número de neurônios em cada camada	6 e 4
EQM	-11

Fonte: Autor.

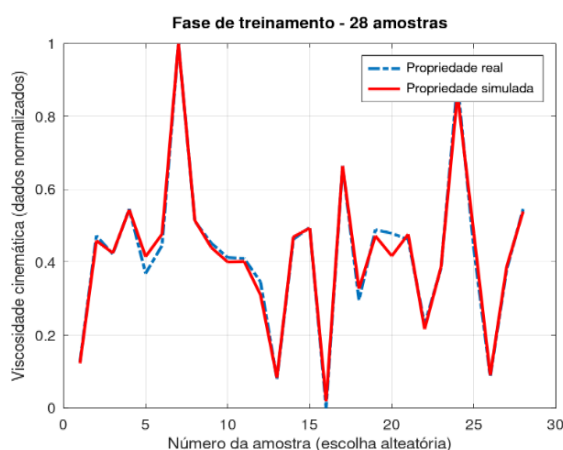
## 5 RESULTADOS E DISCUSSÃO

### 5.1 Predição da Viscosidade Cinemática a 40°C mm<sup>2</sup>.s<sup>-1</sup>.

A rede gera um conjunto de pesos sinápticos, que são inseridos dentro de uma matriz. Esses pesos podem ser utilizados para a elaboração de um programa ou aplicativo, que se inseridos os dados básicos de ácidos graxos, fará uma previsão das propriedades físico-químicas do biodiesel.

A Figura 6 ilustra o comportamento da rede neural durante a fase de treinamento, estabelecendo uma comparação entre a propriedade real (linha azul) e a simulada (linha vermelha). Nessa fase a rede utilizou 28 amostras e os dados foram normalizados automaticamente pela rede. É possível observar uma boa adaptação da rede proposta em relação às amostras analisadas. O EQM obtido na fase de treinamento da RNA foi de 0.000251, mostrando um resultado satisfatório de aproximação da resposta da rede, tendo-se curvas praticamente sobrepostas.

Figura 6: Fase de treinamento da rede para viscosidade cinemática




Fonte: Autor.

Os dados da fase de teste (Figura 7) foram dispostos por seis amostras totalizando 20% do total de amostras da base de dados, onde são escolhidas aleatoriamente pela RNA para a comparação real. Para analisar o gráfico dessa fase, devemos comparar, para cada amostra selecionado, a amplitude da saída desejada (bolinha na cor azul) com a respectiva saída simulada ou saída obtida pela rede (bolinha vermelha). Além disso, quanto mais próxima estiverem, melhor será o resultado na estimativa da propriedade.



Observa-se que nas amostras 2, 5, 29 e 33 há uma grande proximidade dos resultados os resultados das propriedades reais com os do simulado. Por outro lado, não tivemos o mesmo comportamento para as amostras 18 e 22, nos quais apresentam uma considerável discrepância. Justificando tal comportamento, presume-se que existe algum erro de dados dispostos pela literatura utilizada ou a própria rede não conseguiu aprender suficiente com os dados de treinamento para estimar os valores de teste. No entanto, como o EQM nesta fase foi de 0.029346, o qual é consideramos aceitável devido ao baixo valor, validou-se, portanto, o modelo de estimação.

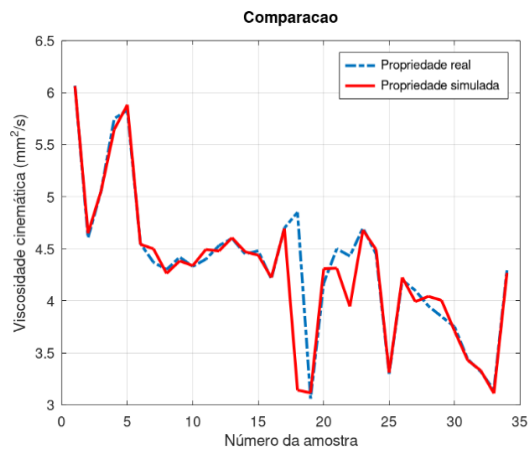
Figura 7: Fase de teste da rede



Fonte: Autor.

Por fim, com a RNA validada, faz-se um comparativo da saída desejada (Viscosidade Cinemática real) e saída simulada de todas as amostras da base de dados (Figura 8), tendo-se curvas bem próximas, com discrepância acentuada na amostra 18, como mencionado anteriormente.

Figura 8: Fase de comparação real



Fonte: Autor.

Viegas (2014) realizou uma avaliação da convergência através de modelos de RNAs aplicadas para a predição simultânea do índice de iodo, viscosidade e massa específica do biodiesel. Ele utilizou todos os ésteres presentes no biodiesel como variáveis de entrada, como consequência a porcentagem de cada éster é o principal fator de influência nos resultados. As redes treinadas pelo método de Viegas fornecem três variáveis de saída (índice de iodo, viscosidade e densidade), diferente das redes do presente trabalho, cujo informa as propriedades especificadas e delimitadas pelo programador (viscosidade cinemática ou massa específica). Apesar da relação entre os erros quadráticos médios (EQM) mostrados na Tabela 5 serem próximos, contudo, não se pode afirmar que o comparativo seja totalmente válido, pois as variáveis de entrada e rodagem são distintas. Desse modo não podemos comparar qual rede é a melhor, porém podemos validar que as redes dos dois trabalhos obtiveram um bom resultado das relações entre a composição do biodiesel e as propriedades, gerando um EQM baixo.

Tabela 5: Resultados obtidos pelos autores através de diferentes métodos e redes


Autores	Tipo da rede	EQM	
		Treinamento	Teste
(VIEGAS, 2014)	BFGS	0.008148	0.068841
(VIEGAS, 2014)	Gradiente descendente	0.011454	0.032673
Autor			
Viscosidade Cinemática	Multicamadas	0.000251	0.029346
Autor			
Massa específica	Multicamadas	0.000104	0.029726

Fonte: (VIEGAS, 2014).

## 5.2 Predição da massa específica $\text{kg.m}^{-3}$ .

De forma similar ao da viscosidade cinemática, a Figura 9 apresenta o comportamento da rede neural durante a fase de treinamento da rede, estabelecendo uma comparação entre a propriedade real (linha azul) e a simulada (linha vermelha). O erro quadrático médio na fase de treinamento da RNA, para esse caso foi de  $\text{EQM} = 0.000256$ .


Figura 9: Fase de treinamento da rede massa específica



Fonte: Autor.

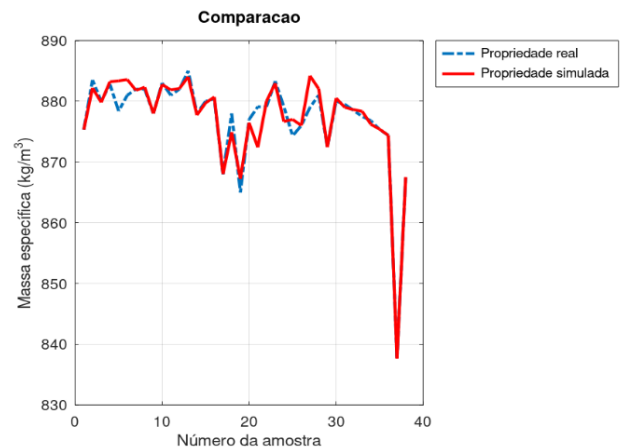
Em relação a fase de teste, as amostras foram 5, 6, 10, 15, 21, 27 e 30, no qual obteve-se um EQM de 0.003282. Este valor foi menor que o obtido na fase de teste da viscosidade cinemática. Desta forma, também se valida o modelo de estimação. A Figura 10 apresenta leves discrepâncias para amostras 5, 6 e 21, porém sem comprometer o comportamento da curva simulada em relação a curva real referente a propriedade da massa específica. Por fim, Figura 11 compara-se a propriedade simulada com a real, fornecendo os valores da massa específica de acordo com a disposição das amostras. O comportamento gráfico da curva simulada é próximo a do resultado real demonstrando um resultado satisfatório.

Figura 10: Fase de teste da rede



Fonte: Autor.

Figura 11: Fase de comparação real



Fonte: Autor.

### 5.3 Processamento e execução da rede com os dados de produção do biodiesel

A Figura 12 representará o gráfico de treinamento para a previsão até o ano de 2025 e o EQM obtido foi de 0.000000, desse modo a linha da demanda simulada está totalmente

sobreposta a da real, logo não há percepção da diferença existente entre as duas linhas. Esse valor demonstra o quanto a rede aprendeu na fase de treinamento, sendo que quanto mais próximo de zero melhor.


Figura 12: Fase de treinamento da previsão para biodiesel até 2025



Fonte: Autor.

De modo semelhante a Figura 13 para o treinamento da rede com a previsão até o ano de 2028 obteve o EQM de 0.000001, assemelhando-se os resultados simulados com os reais.

Figura 13: Fase de treinamento da previsão para biodiesel até 2028



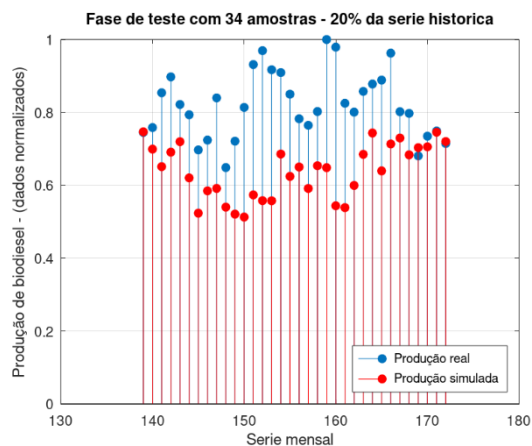
Fonte: Autor

#### 5.4 Previsão da produção do biodiesel

Na fase de teste a rede utilizou 20 % dos dados que não foram utilizados no treinamento. Nessa etapa o EQM = 0.023611 da Figura 14 para o ano de 2025 e EQM = 0.028336 da Figura 15 para o ano de 2028. Os gráficos mostram que as bolas azuis não se aproximam das


vermelhas, porém observando as tendências das curvas como uma linha, o comportamento delas se assemelham.

Figura 14: Fase de teste para biodiesel até 2025



Fonte: Autor.

Figura 15: Fase de teste para biodiesel até 2028



Fonte: Autor.

Caires e Simonelli (2021) obteve dados para a previsão da demanda do biodiesel até o ano de 2050, usando a rede perceptron de múltiplas camadas (MLP). Caires modificou previamente os dados de entrada da rede utilizando dois cenários da porcentagem, entre o período de 2005 e 2019, um para o B15 e outro B20, desse modo as previsões futuras utilizariam esses resultados como base. Os resultados obtidos por ele através de análise gráfica, estima-se que a demanda no cenário do B20 para o ano de 2028, será um pouco menos de 15 milhões de  $m^3$ .

As Figuras 16 e 17 expressam os valores estimados em volumes reais em  $m^3$ . A série gráfica da Figura 16 referente a previsão do biodiesel até 2025, apresentou consistência na curva dos dados gerados em relação com a variação mensal a da série histórica existente. A grande oscilação do gráfico real, ocorre entorno de 24 meses, que pode ser explicado devido a pandemia do Covid-19, cuja desestabilizou a produção e o comercio dos combustíveis. A previsão mostra que a produção tenderá a recuperar a produção ocorrida devido a pandemia, porém até o ano de 2025 o mercado ainda sofrerá dificuldades para tornar a estabilizar.

Figura 16: Fase da previsão para biodiesel até 2025



Fonte: Autor.

A previsão da demanda do biodiesel até o ano de 2028 (Figura 17), mostra uma instabilidade em um ponto da execução da rede. O possível motivo é devido a ordem de previsão ser quase 40% da quantidade de dados inseridos na rede, ou seja, a rede terá pouca informação e estimará muitos meses, contudo de modo geral seu o comportamento não é afetado. Se compararmos os dois resultados entre a previsão de 2025 e 2028 analisamos uma estabilidade na demanda, não ultrapassando a 600 mil m<sup>3</sup> de biodiesel 2022 até 2028.

Figura 17: Serie previsão para biodiesel até 2028



Fonte: Autor.

Podemos presumir que fatores políticos alterando a porcentagem obrigatória pode variar os resultados, assim como o aumento das novas tecnologias (carros movidos a bateria, hidrogênio e biogás) estão ganhando espaço no mercado gradativamente.

As Tabelas 6 e 7 mostram respectivamente os volumes referentes a previsão da demanda de biodiesel em m<sup>3</sup> para os períodos até 2025 e até 2028. Comparando os dois resultados em

seus respectivos meses divergem, por exemplo o resultado de janeiro de 2024 da Tabela 6 foi 536078.6 m<sup>3</sup> e da Tabela 7 para o mesmo período 476734.0 m<sup>3</sup>, porém em termos analíticos servirá para ter noção da quantidade de matéria prima a ser produzida, para que a quantidade final de produto esteja próxima dessa faixa de variação.

Tabela 6: Volume da produção de biodiesel em m<sup>3</sup> com os dados referentes a previsão até janeiro de 2025

	2022	2023	2024	2025
<b>jan</b>	-	487703	536079	509249
<b>fev</b>	-	501532	516406	-
<b>mar</b>	-	568737	530242	-
<b>abr</b>	-	541774	559733	-
<b>mai</b>	503752	566440	561703	-
<b>jun</b>	500622	562654	553405	-
<b>jul</b>	511301	545532	557526	-
<b>ago</b>	523236	539818	548863	-
<b>set</b>	524928	559205	501590	-
<b>out</b>	509265	573545	547630	-
<b>nov</b>	531867	571780	553801	-
<b>dez</b>	535777	578345	539065	-

Fonte: Autor.

Tabela 7: Volume da produção de biodiesel em m<sup>3</sup> com os dados referentes a previsão até janeiro de 2028

	2022	2023	2024	2025	2026	2027	2028
<b>jan</b>	-	347100	476734	501384	499010	531736	567137
<b>fev</b>	-	384996	531676	557182	534908	562184	-
<b>mar</b>	-	522266	566857	578988	549739	564842	-
<b>abr</b>	-	482791	557250	74319.2	554979	578309	-
<b>mai</b>	541341	537652	570967	579652	557583	587334	-
<b>jun</b>	531239	563362	553291	572856	533143	563710	-
<b>jul</b>	504701	538856	581351	559836	552727	569520	-
<b>ago</b>	549171	523336	599029	567989	527072	583439	-
<b>set</b>	530813	539594	588936	570172	549956	575530	-
<b>out</b>	498296	516681	577476	549142	556401	582445	-
<b>nov</b>	512741	516427	571547	561227	569495	589884	-
<b>dez</b>	485851	536847	572829	549702	563042	581423	-

Fonte: Autor.

## 6 CONCLUSÃO

Diante da predição dos valores de massa específica e viscosidade cinemática para diferentes amostras de biodiesel, observou-se que a RNA implementada, apresentou resultados satisfatórios incluindo todo o processo de validação do modelo (definição dos parâmetros de rede e o processo de validação do modelo com as etapas de treinamento e teste). Destaca-se que a predição de propriedades do biodiesel, via ferramentas computacionais, é possível, porém para otimização e melhores resultados é necessário um banco de dados maior com mais de 150 amostras para a alimentação da rede.

O trabalho mostra que a ferramenta RNA do tipo NAR pode prever a demanda dos combustíveis para os próximos anos. Em comparação com trabalhos semelhantes, podemos dizer que esse tipo de rede se sobrepôs através das análises do EQM. Quanto mais próxima a janela de previsão e mais dados para a alimentação da rede, teremos melhores resultados quando analisados pelo erro médio quadrático. Podemos concluir que sabendo a demanda dos combustíveis será possível analisar o melhor cenário para projetar a quantidade de matéria prima a ser utilizada e uma pré-avaliação da quantidade de importação de barris de petróleo.



## 7 REFERÊNCIAS

ANDRÉ. **REDES NEURAIIS ARTIFICIAIS**. Universidade de São Paulo. Site ICMC. 2018. Diretório: /andre/research/neural/. Disponível em: <[LINK](#)>. Acesso em: 05 dez. 2022.

ANP. **RESOLUÇÃO ANP Nº 45, DE 25 DE AGOSTO DE 2014**. 2014b. Disponível em: <[LINK](#)>. Acesso em: 22 nov. 2022.

ANP. **NOTA TÉCNICA Nº 10/2021**: Especificações Nacionais do Biodiesel (B100). 2021. Disponível em: <[LINK](#)>. Acesso em: 02 nov. 2022.

ANVISA. **Resolução-rdc nº 270, de 22 de setembro de 2005**. Disponível em: <[LINK](#)>. Acesso em: 31 out. 2022.

ARANCIBIA, Esteban Patricio Manuel Fernández. **Avaliação de configurações de rede neural para previsão do consumo de energia de sistemas de climatização**. 2008. 62 f. TCC (Graduação) - Curso de Engenharia Mecânica, Universidade de São Paulo, São Paulo, 2008.

AZEVEDO, Paulo Gabriel Ferreira *et al.* **Correlação empírica para massa específica de biodiesel de fontes diversas e suas misturas com o diesel**. Revista Brasileira de Gestão Ambiental e Sustentabilidade, [S.L.], v. 7, n. 16, p. 707-716, 2020a. Revista Brasileira de Gestao Ambiental e Sustentabilidade. [http://dx.doi.org/10.21438/rbgas\(2020\)071617](http://dx.doi.org/10.21438/rbgas(2020)071617).

**BIODIESEL**. ANP: Agência Nacional do Petróleo, Gás Natural e Biocombustíveis, 13 jul. 2020. Disponível em: <[LINK](#)>. Acesso em: 27 out. 2022.

**BIODIESELBR. Por que mesmo reduziram a mistura de biodiesel e destruíram um programa que é patrimônio nacional?** 13 dez 2021. Disponível em: <[LINK](#)>. Acesso em: 05 dez. 2022.

CAIRES, Kaique Vitor Louzada; SIMONELLI, George. **Previsão da demanda brasileira de biodiesel utilizando redes neurais artificiais**. Research, Society And Development, [S.L.], v. 10, n. 5, 2 maio 2021. Research, Society and Development. <http://dx.doi.org/10.33448/rsd-v10i5.13381>.

CAVALCANTE, Raquel Massad. **Predição da densidade de biodiesel proveniente de diferentes matérias-primas**. Dissertação (Mestrado em Tecnologia de Processos Químicos e

Bioquímicos) – Universidade Federal do Rio de Janeiro, Escola de Química, Rio de Janeiro, 2010.

COIMBRA, Alberto Luiz. **Mecânica dos Fluidos**. Rio de Janeiro: E-Papers Serviços Editoriais, 2015. 386 p.

DEMUTH, H., BEALE, M., & HAGAN, M. (2015). *Neural Network Toolbox. User's Guide*. MATLAB®. Massachusetts: The MathWorks®, Inc.

GARCIA, Camila Martins. **Transesterificação de óleos vegetais**. 136 f. Dissertação (Mestrado) - Curso do Instituto de Química da Unicamp, Universidade Estadual de Campinas, Campinas, SC, 2006.

GOV. **Programa Nacional de Produção e Uso do Biodiesel (PNPB)**. Disponível em: <[LINK](#)>. Acesso em: 31 out. 2022.

JAHIRUL, M *et al.* **The Use of Artificial Neural Networks for Identifying Sustainable Biodiesel Feedstocks**. *Energies*, [S.L.], v. 6, n. 8, p. 3764-3806, 29 jul. 2013. MDPI AG. <http://dx.doi.org/10.3390/en6083764>.

KNOTHE, Gerhard, *et al.* *Manual do Biodiesel*. 1. ed. São Paulo: Blücher, 2006. 352 p.

MALESKI, Michele Maisa. **Produção de ésteres por biocatalisador utilizando gordura residuária proveniente da indústria de alimentos e energia**. Universidade Federal da Fronteira sul. Chapecó, SC. 2018.

MARCINIUK, Letícia Ledo. **Catalisadores heterogêneos ácidos inéditos para a produção de ésteres metílicos e etílicos de óleos vegetais**. Campinas, SP: [s.n], 2007.

MARTINS, Herbert & CARVALHO, A. M. **Biodiesel: produção e desafios**. Belo Horizonte: Sempre, 2007.

OLIVEIRA, Flávia C. C, *et al.* **Biodiesel: Possibilidades e Desafios**. UFMG. Belo Horizonte, MG. *Química Nova na Escola*, n. 28, maio 2008.

PINHO, Lorena de Andrade; TEIXEIRA, Francisco Lima Cruz. **BIODIESEL NO BRASIL: uma análise da regulação e seus reflexos na diversificação das matérias-primas usadas no processo de produção**. Salvador, Ba. 2005. p. 141-161. Disponível em: <[LINK](#)>. Acesso em: 27 out. 2022.

PÉREZ, F. L. Análise de Séries Temporais. Site UFPR. 2022. Departamento de estatística. Cap 3. Disponível em: <[LINK](#)>. Acesso em: 17 jan. 2022.

PRABU, N Manikanda. **Experimental Analysis of Jatropha Curcas Bio-Diesel for Optimum Blend Characteristics**. Bonfring International Journal Of Industrial Engineering And Management Science, [S.I.], v. 3, n. 2, p. 63-69, 30 jun. 2013. Bonfring. <http://dx.doi.org/10.9756/bijiems.4667>.

RAMOS, L. P *et al.* **Biodiesel: Matérias-Primas, Tecnologias de Produção e Propriedades Combustíveis**. Rev. Virtual Quim., 2017, 9 (1), 317-369.

RAMOS, Marco Antônio Fernandes. **SISTEMA DE IDENTIFICAÇÃO E LOCALIZAÇÃO DE FALTAS EM LINHAS DE TRANSMISSÃO BASEADO EM REDES NEURAIS**. Puc-Rio, Rio de Janeiro, v. 1, n. 1, p. 17-37, maio 2003. Faculdades Catolicas. <http://dx.doi.org/10.17771/pucRio.acad.3509>.

SILVA, Ivan Nunes da; SPATTI, Danilo Hernane; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para engenharia e ciências aplicadas**. 2. ed. Universidade de São Paulo: Artliber, 2016.

SILVA JÚNIOR, Andouglas. Gonçalves. **Massa específica, peso específico e peso relativo**. [S.I.]: Ifrn, 2016. 35 slides, color.

SILVA, Lizandra Régia Miranda da; GUIMARÃES, Antônio Alisson Pessoa. **ASPECTOS COMPUTACIONAIS DE PREVISÃO DE ENERGIA ELÉTRICA EM CURTO PRAZO DESTINADO AO SISTEMA FOTOVOLTAICO DE MINIGERAÇÃO DO CAMPUS DAS AURORAS (UNILAB-CEARÁ)**. Desvendando a Engenharia: sua abrangência e multidisciplinaridade - Volume 2, [S.L.], p. 87-102, 2021. Editora Científica Digital. <http://dx.doi.org/10.37885/210705575>.

SOUSA, Raquel Machado. **Avaliação da Predição de Algoritmos de Treinamento Supervisionado de Redes Neurais Artificiais Aplicado a Qualidade de Biodiesel**. 2015. 82 f. Dissertação (Mestrado) - Curso de Engenharia de Eletricidade, Universidade Federal do Maranhão, São Luís, 2015.

SCHUCHARDT, U.; SERCHELI, R.; VARGAS, R.M.; **Transesterification of Vegetable Oils: a Review**, Journal Of The Brazilian Chemical Society, Salvador, Ba, v. 9, n. 3, p. 1-2, maio 1998. FapUNIFESP (SciELO). Disponível em: <[LINK](#)>. Acesso em: 27 out. 2022.

VENY, H. *et al.* **Density of Jatropha curcas Seed Oil and its Methyl Esters: Measurement and Estimations.** Int J Thermophys, v. 30, p. 529–541, 2009.

VIEGAS, Isabelle Moraes Amorim. *et al.* **AVALIAÇÃO DE MÉTODOS DE CONVERGÊNCIA NO TREINAMENTO DE REDES NEURAS ARTIFICIAIS APLICADAS À PREDIÇÃO DE ÍNDICE DE IODO, VISCOSIDADE E DENSIDADE EM BIODIESEL.** Cadernos de Pesquisa, [S.L.], p. 40, 17 jul. 2014. Universidade Federal do Maranhão. Disponível em. <[LINK](#)>. Acesso em: 22 dez. 2022.

## APÊNDICE A – DADOS UTILIZADOS NA RNA DO TIPO FEEDFORWARD MULTICAMADAS

Tabela 8: Porcentagem dos ésteres de cada amostra e valor de suas propriedades

Nº das amostras	Composição química do biodiesel - percentual de ésteres												Propriedades	
	C8:0	C10:0	C12:0	C16:0	C:16:1	C18:0	C18:1	:18:1trans	C18:2	C18:3	C20:0	C22:1	Massa específica a 20 °C (Kg/m3)	Viscosidade Cinemática a 40 °C (mm²/s)
Amostra 01	0	0	0	26.18	1.91	33.69	30.09	1.74	0.76	0	0.3	0	875.3	6.065
Amostra 02	0	0	0	12.51	0.15	4.89	34.77	0.68	46.48	0	0.33	0	883.5	4.604
Amostra 03	0	0	0	23.2	6.07	6.31	39.75	0	22.07	0	0.12	0	880	5.057
Amostra 04	0	0	0	13.3163	0	4.8139	24.5429	0	55.3923	0.115	0.4174	0	882.8	5.75
Amostra 05	0	0	0	16.0767	0	5.8155	25.4624	0	50.0894	0.181	0.5176	0	878.4	5.83
Amostra 06	0	0	0	15.64	0.32	2.1	54.89	0	19.56	4.88	2.24	0	881	4.55
Amostra 07	0	0	0	11.43	0.07	4.03	24.85	0	55.33	3.34	0.25	0	882	4.37
Amostra 08	0	0	0	5.93	0.14	3.44	36.22	0	52.95	0.38	0.46	0	882	4.3
Amostra 09	0	0	0	12.23	0.13	2.62	31.4	0	51.21	0.85	0.32	0	878	4.42
Amostra 10	0	0	0	21.47	0.56	2.61	18.21	0	55.45	0.15	0.06	0	883	4.33
Amostra 11	0	0	0	6.23	0.34	2.49	61.46	0	22.12	5.11	1.43	0	881	4.4
Amostra 12	0	0	0	13.27	0.86	3.69	68	0	12.48	0.76	0.48	0	882	4.53
Amostra 13	0	0	0	6.7	0.08	2.4	11.5	0	79	0.15	0	0	885	4.6
Amostra 14	0	0	0	5.82	0.29	2.74	79.3	0	10.39	0.46	0.16	0	878	4.45
Amostra 15	0	0	0	3.49	0	0.85	64.4	0	22.3	8.23	0	0	880	4.48
Amostra 16	0	0	0	24.59	0	4.45	42.48	0	26.92	0.49	0.57	0	880.4	4.211
Amostra 17	0	0	0	5.89	0	4.58	46.08	0	9.78	4.24	0	21.55	868	4.7
Amostra 18	0	0	14.8	10.8	1	3.1	45.6	0	11.4	0	0	0	878	4.85
Amostra 19	0	0	15.6	10.6	1.2	3	44.7	0	11.9	0	0	0	865	3.06
Amostra 20	0	0	0	0.6	0.1	1.1	25.3	0	70.4	0.7	0	0.2	877	0
Amostra 21	0	0	0	0.2	0.2	1.5	43.3	0	35.8	17.6	0	0	879.1	0
Amostra 22	0	0	0	0.4	0.1	1.1	19	0	78.4	1.1	0	0	879.1	0
Amostra 23	0	0	0	0.4	0	0.7	10.2	0	74.1	14.4	0	0	883.3	0
Amostra 24	0	0	0	12.8	1.1	4.3	28.9	0	46.5	4.8	0.3	0.1	879.1	4.17
Amostra 25	0	0	0	12.9	1.1	4.3	29	0	46.9	4.6	0.3	0	874.3	4.5
Amostra 26	0	0	0	9.3	0	6.3	18.8	0	42.8	22.4	0.3	0	876	4.43
Amostra 27	0	0	0	5.7	0	3.9	11.8	0	71.6	6.9	0	0	879	4.7
Amostra 28	0	0	0	13.38	0	5.72	33.59	0	45.91	0	0	0	881	4.45
Amostra 29	4.27	3.96	35.19	8.82	0	3.08	29.21	0	4.07	0	0	0	872.5	3.3
Amostra 30	0.58	0.47	4.62	12.26	0	5.83	32.93	0	41.23	0	0	0	880	4.2
Amostra 31	0.85	0.84	8.34	11.92	0	5.46	32.37	0	37.09	0	0	0	879.5	4.1
Amostra 32	1.37	1.22	12.13	11.26	0	5.26	31.78	0	32.58	0	0	0	878.5	3.95
Amostra 33	1.85	1.59	15.65	10.94	0	4.47	31.04	0	29.18	0	0	0	877.5	3.85
Amostra 34	1.95	1.93	18.94	10.39	0	4.51	31.68	0	25.19	0	0	0	876.8	3.75
Amostra 35	6.41	6.06	46.93	8.07	0	3.09	11.73	1.89	0	0	0	0	875.36	3.44
Amostra 36	3.49	3.27	46.03	8.27	0	2.06	16.17	5.22	0	0	0	0	874.4	3.32
Amostra 37	0	0	0.2	47.4	0	4.7	36.5	0	9.6	0.4	0	0	837.6	3,144
Amostra 38	0	0	0	18.7	0	4.3	28.4	0	42.6	3.8	0	0	867.6	4,294

Fonte: Autor.

Tabela 9: Referência das amostras de acordo com sua numeração

<b>Nº das amostras</b>	<b>Matéria prima</b>	<b>Referência</b>
Amostra 01	Sebo	(CUNHA, 2008)
Amostra 02	Soja	(CUNHA, 2008)
Amostra 03	Frango	(CUNHA, 2008)
Amostra 04	Soja (metílico)	(CANDEIA, 2008)
Amostra 05	Soja (etílico)	(CANDEIA, 2008)
Amostra 06	Alga	(YAŞAR, 2020)
Amostra 07	Soja	(YAŞAR, 2020)
Amostra 08	Girassol	(YAŞAR, 2020)
Amostra 09	Milho	(YAŞAR, 2020)
Amostra 10	Caroço de algodão	(YAŞAR, 2020)
Amostra 11	Canola	(YAŞAR, 2020)
Amostra 12	Oliva	(YAŞAR, 2020)
Amostra 13	Cártamo	(YAŞAR, 2020)
Amostra 14	Avelã	(YAŞAR, 2020)
Amostra 15	Colza	(YAŞAR, 2020)
Amostra 16	Blend: palm and sesame	(MUJTABA <i>et al.</i> , 2021)
Amostra 17	Karanja	(KUMAR; SINGH, 2020)
Amostra 18	Óleo de semente (convencional)	(ALLAMI <i>et al.</i> , 2020)
Amostra 19	Óleo de semente (ultra)	(ALLAMI <i>et al.</i> , 2020)
Amostra 20	Amendoim	INMETRO
Amostra 21	Canola	INMETRO
Amostra 22	Gergelim	INMETRO
Amostra 23	Soja	INMETRO
Amostra 24	Óleo residual (metílico)	(SILVA, 2011)
Amostra 25	Óleo residual (etílico)	(SILVA, 2011)
Amostra 26	Óleo de semente manketti	(KIVEVELE; MBARAWA, 2011)
Amostra 27	Óleo de Croton megalocarpus	(KIVEVELE; MBARAWA, 2011)
Amostra 28	BS100	(OLIVEIRA, 2016)
Amostra 29	BM100	(OLIVEIRA, 2016)
Amostra 30	BSM10	(OLIVEIRA, 2016)
Amostra 31	BSM20	(OLIVEIRA, 2016)
Amostra 32	BSM30	(OLIVEIRA, 2016)
Amostra 33	BSM40	(OLIVEIRA, 2016)
Amostra 34	BSM50	(OLIVEIRA, 2016)
Amostra 35	coco babaçu (metílico)	(ALVES, 2017)
Amostra 36	coco babaçu (etílico)	(ALVES, 2017)
Amostra 37	destilado de ácido graxo de palma	(AGUIEIRAS <i>et al.</i> , 2017)
Amostra 38	destilado de ácido graxo de soja	(AGUIEIRAS <i>et al.</i> , 2017)

Fonte: Autor.