

UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ

THAIS COFFANI COSTA

**DETERMINAÇÃO DE PARÂMETROS CINÉTICOS DA GASEIFICAÇÃO DE
BIOMASSAS DO SUL DO BRASIL POR MEIO DE REDES NEURAIS ARTIFICIAIS**

FRANCISCO BELTRÃO

2023

THAIS COFFANI COSTA

**DETERMINAÇÃO DE PARÂMETROS CINÉTICOS DA GASEIFICAÇÃO DE
BIOMASSAS DO SUL DO BRASIL POR MEIO DE REDES NEURAIS ARTIFICIAIS**

**Determination of Kinetic Parameters of the Gasification of Southern Brazilian
Biomass Using Artificial Neural Networks**

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

2023



[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.

THAIS COFFANI COSTA

**DETERMINAÇÃO DE PARÂMETROS CINÉTICOS DA GASEIFICAÇÃO DE
BIOMASSAS DO SUL DO BRASIL POR MEIO DE REDES NEURAS ARTIFICIAIS**

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: 08/Dezembro/2023

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

Michele Di Domenico
Doutorado em Engenharia Química
Universidade Tecnológica Federal do Paraná

Douglas Junior Nicolin
Doutorado em Engenharia Química
Universidade Tecnológica Federal do Paraná

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

FRANCISCO BELTRÃO

2023

Dedico este trabalho à minha família, em reconhecimento ao constante apoio que me proporcionaram. Também dedico a mim mesma, pelos momentos de determinação e superação diante das adversidades.

AGRADECIMENTOS

Gostaria de expressar minha profunda gratidão a todas as pessoas que desempenharam papéis cruciais ao longo desta fase de minha vida. Desde já, peço desculpas àqueles que, porventura, não estejam mencionados aqui, mas é certo que fazem parte dos meus pensamentos e da minha gratidão.

Em primeiro lugar, estendo meu agradecimento ao meu orientador, Claiton Zanini Brusamarello, que não apenas me introduziu ao universo das redes neurais, mas também guiou cada passo desta jornada durante a elaboração deste Trabalho de Conclusão de Curso.

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), expresso minha sincera gratidão pela bolsa de incentivo concedida.

À Universidade Tecnológica Federal do Paraná, minha alma mater, agradeço por abrir suas portas e proporcionar um ambiente propício para minha formação acadêmica e pessoal. Cada oportunidade oferecida contribuiu significativamente para o meu crescimento.

À minha ampla rede de apoio, composta por familiares, amigos, meu fiel companheiro José e minha maior inspiração Jandira, expresso meu mais profundo agradecimento. Seu constante apoio, orientação e aceitação da minha pessoa foram elementos-chave para o sucesso desta jornada.

Conhecimento deve pertencer a todas as pessoas
(ELBAKYAN, 2020).

RESUMO

Este estudo aplicou redes neurais artificiais para estabelecer a correlação entre os constituintes da biomassa, análise elementar e análise imediata, especificações do reator e os parâmetros cinéticos (energia de ativação e fator pré-exponencial) da gaseificação de biomassa. Foram desenvolvidos três modelos de redes neurais artificiais, um para cada um dos dois parâmetros cinéticos e um para todos os parâmetros em uma única rede neural artificial. O conjunto de dados continha 76 experimentos, sendo 40 dados de biomassas diversas encontradas na literatura e 36 dados de biomassas amplamente utilizadas na região Sul do Brasil, os quais foram utilizados para desenvolver e testar as redes neurais. O estudo demonstrou eficácia na previsão da energia de ativação, tanto globalmente, quanto especificamente para as biomassas do sul do Brasil, atingindo coeficiente de determinação de 0,8571 e 0,9545, respectivamente. No entanto, as redes neurais artificiais utilizadas para previsão do fator pré-exponencial mostraram-se ineficazes, sendo a ausência de muitos valores desse parâmetro no conjunto de dados a principal razão para tal.

Palavras-chave: feed-forward; energia de ativação; fator pré-exponencial; energia.

ABSTRACT

This study applied artificial neural networks to establish the correlation between biomass constituents, ultimate analysis and proximate analysis, reactor specifications and the kinetic parameters (activation energy and pre-exponential factor) of biomass gasification. Three ANN models were developed, one for each of the two kinetic parameters and one for all parameters in a single ANN. The dataset included 76 experiments, comprising 40 data points from various biomasses found in the literature and 36 data points from widely used biomasses in the Southern region of Brazil. These data were used to train and test the neural networks. The study demonstrated effectiveness in predicting activation energy, both globally and specifically for biomasses from the Southern region of Brazil, achieving determination coefficients of 0.8571 and 0.9545, respectively. However, the artificial neural networks used for predicting the pre-exponential factor proved ineffective, with the lack of many values for this parameter in the dataset being the main reason for this.

Keywords: feed-forward; activation energy; pre-exponential factor; energy.

LISTA DE ILUSTRAÇÕES

Figura 1 – Fontes de biomassa	15
Figura 2 – Estimativa da produção sustentável em florestas plantadas Pinus por estado	16
Figura 3 – Rendimento médio por ano da safra e produto na região sul do Brasil	16
Figura 4 – Oferta interna de energia elétrica por fonte	17
Figura 5 – Etapas da gaseificação	21
Quadro 1 – Vantagens e desvantagens dos agentes de gaseificação	22
Figura 6 – Tipos de gaseificadores.....	23
Quadro 2 – Vantagens e desvantagens dos gaseificadores de leito fixo e fluidizado.....	24
Figura 7 – Comparação entre modelos	26
Figura 8 – Esquema de um neurônio biológico e de um modelo de neurônio artificial	27
Figura 9 – Elementos da rede neural artificial	28
Figura 10 – Diferentes tipos de arquitetura de redes neurais artificiais	29
Quadro 3 – Estudos correlacionados	30
Figura 11 – Fluxograma dos procedimentos metodológicos.....	33
Figura 12 – Rede neural artificial	37
Quadro 4 – Configuração de treinamento e teste.....	37
Figura 13 – Funções de ativação	38
Quadro 5 – Variações de parâmetros	39
Figura 14 – Dados faltantes em porcentagem	42
Figura 15 – Matriz de correlação dos dados	42
Quadro 6 – Teste de modelos e porcentagens de treinamento e teste	43
Figura 16 – Configuração RNA para previsão da energia de ativação	45
Figura 17 – Configuração RNA para o fator pré exponencial.....	45
Figura 18 – Gráfico de dispersão dos valores reais vs previstos da RNA de energia de ativação	46
Figura 19 – Gráfico de dispersão dos valores reais vs previstos da RNA do fator pré exponencial	46
Figura 20 – Configuração RNA para o fator pré exponencial para prever biomassas do Sul.....	48
Figura 21 – Gráfico de dispersão dos valores reais vs previstos da RNA para previsão de biomassas do Sul	48
Figura 22 – Configuração RNA para o fator pré-exponencial para prever biomassas do Sul.....	49
Figura 23 – Gráfico de dispersão dos valores reais vs previstos da RNA do fator pré exponencial de biomassa do Sul.....	50

LISTA DE ABREVIATURAS E SIGLAS

A	Fator pré-exponencial
Ea	Energia de ativação
EMBRAPA	Empresa Brasileira de Pesquisa Agropecuária
EPE	Empresa de Pesquisa Energética
IBÁ	Indústria Brasileira de Árvores
IBGE	Instituto Brasileiro de Geografia e Estatística
IA	Inteligência artificial
IQR	Intervalo interquartil
Q1	Primeiro quartil
Q3	Terceiro quartil
RMSE	Erro quadrático médio
R ²	Coefficiente de determinação
RNAs	Redes neurais artificiais
Linf	Limite inferior
Lsup	Limite superior

SUMÁRIO

1	INTRODUÇÃO	11
1.1	Problema	12
1.2	Justificativa	12
2	OBJETIVOS	14
2.1	Objetivos específicos	14
3	FUNDAMENTAÇÃO TEÓRICA	15
3.1	Biomassa	15
3.1.1	Análise elementar e imediata	17
3.1.2	Casca de arroz	19
3.1.3	Bagaço cana-de-açúcar	19
3.1.4	Madeira pinus	19
3.2	Gaseificação	20
3.2.1	Gaseificadores.....	22
3.2.2	Modelos e parâmetros cinéticos	24
3.3	Redes neurais artificiais	26
3.3.1	Estrutura de uma rede neural.....	27
3.3.2	Feed forward	29
3.4	Estado da arte	30
4	PROCEDIMENTOS METODOLÓGICOS	33
4.1	Base de dados	33
4.2	Pré-processamento de dados	35
4.3	Rede neural artificial	36
4.4	Análise dos resultados	39
5	RESULTADOS	41
5.1	Prevendo parâmetros cinéticos de um conjunto amplo de biomassas 41	
5.2	Prevendo os parâmetros cinéticos das biomassas do Sul do Brasil 47	
6	CONCLUSÃO	51
	REFERÊNCIAS	53
	APÊNDICE A - Base de dados	59

1 INTRODUÇÃO

Atualmente, a crescente atenção voltada às alterações climáticas destaca a necessidade premente de diversificar a matriz energética, reduzindo a histórica dependência de combustíveis derivados de recursos fósseis. Nesse contexto, a biomassa emerge como uma opção promissora, oferecendo uma fonte abundante e de grande potencial para impulsionar a transição em direção a fontes de energia renováveis e limpas, tanto em países desenvolvidos quanto em desenvolvimento.

A gaseificação de biomassa representa uma alternativa viável para o uso de fontes de energia renovável, proporcionando uma conversão térmica mais eficiente e com menor impacto ambiental. A biomassa é reconhecida como uma fonte sustentável de energia, absorvendo gás carbônico durante a fotossíntese e, assim, contribuindo para um saldo próximo de zero de emissão de CO₂. Além disso, a cogeração de energia a partir da biomassa pode reduzir custos e aumentar a eficiência energética em processos industriais (Nemer, 2010).

Loo e Koppejan (2008) destacam que a gaseificação de biomassa não apenas oferece vantagens ambientais, mas também sociais e econômicas. A biomassa tem o potencial de gerar mais empregos em comparação com o carvão mineral, reduzindo a dependência de combustíveis importados e, conseqüentemente, os gastos associados.

Os estudos de cinética de gaseificação desempenham um papel crucial na fase de projeto de gaseificadores industriais, fornecendo modelos precisos que incorporam os parâmetros dinâmicos do processo (Felix *et al.*, 2022). Para aprimorar estimativas e reduzir custos associados à coleta de dados, as redes neurais artificiais (RNAs) têm se destacado como uma alternativa eficaz em comparação com métodos tradicionais (Da Silva Binoti *et al.*, 2015).

Segundo Nunes *et al.* (2022), a inteligência artificial, incluindo as RNAs, desempenha um papel fundamental na inovação tecnológica. A previsão, habilitada por RNAs, é crucial para antecipar eventos futuros, fornecendo *insights* valiosos para o planejamento e a tomada de decisões (Cotino, 2017).

Diante desse cenário, este trabalho visa criar uma RNA do tipo feed-forward capaz de prever com precisão os parâmetros cinéticos na gaseificação de biomassa, com foco nas principais biomassas do sul do Brasil, como bagaço de cana-de-açúcar, casca de arroz e madeira pinus. Essa abordagem não só representa um avanço

tecnológico, mas também contribui para a preservação ambiental, promovendo a adoção de tecnologias sustentáveis, como a gaseificação de biomassa, e gerando benefícios econômicos para a região.

1.1 Problema

A gaseificação de biomassa é uma técnica promissora para a produção de energia renovável e limpa, mas ainda há desafios a serem enfrentados para a sua utilização em larga escala.

Um dos principais problemas é a determinação dos parâmetros cinéticos da reação, que são essenciais para o projeto e otimização de processos de gaseificação. A determinação desses parâmetros por meio de experimentos laboratoriais é demorada e cara, o que dificulta o desenvolvimento de processos mais eficientes.

Além disso, a singularidade de cada biomassa dificulta a reprodução dos resultados, uma vez que cada tipo de biomassa possui suas próprias características distintas. Isso implica que as reações de gaseificação são influenciadas pela natureza específica da biomassa utilizada. Como resultado, a aplicação dos parâmetros cinéticos determinados para uma biomassa, em outra se torna um problema.

1.2 Justificativa

A utilização da inteligência artificial neste projeto tem o potencial de prever e otimizar os dados cinéticos de gaseificação de várias biomassas sem a necessidade de realizar uma grande quantidade de experimentos laboratoriais. Além disso, essa tecnologia pode identificar a viabilidade do aproveitamento dessas biomassas de maneira rápida e econômica.

Para este projeto, foi selecionado um conjunto de biomassas mais utilizadas na região sul do Brasil, que inclui o bagaço de cana-de-açúcar, a casca de arroz e a madeira pinus. Essa escolha foi baseada no Plano Nacional de Energia 2030, que destaca essas biomassas como potenciais fontes de energia renovável de forma sustentável na região. O objetivo principal é desenvolver um modelo de rede neural artificial capaz de prever os parâmetros cinéticos de gaseificação dessas biomassas e, posteriormente, verificar sua utilidade para prever os parâmetros de outras biomassas.

Ademais, a aplicação da inteligência artificial nesse estudo pode ser uma forma eficaz de divulgar e incentivar o uso de tecnologias sustentáveis para produção de energia, alinhando-se com as metas da Agenda 2030 para o Desenvolvimento Sustentável. Com isso, é possível contribuir para a construção de um futuro mais próspero e saudável para o país e para o mundo.

2 OBJETIVOS

Este trabalho tem como objetivo desenvolver uma rede neural artificial (RNA) do tipo feed-forward, capaz de prever os parâmetros cinéticos da energia de ativação e o fator pré-exponencial em um processo de gaseificação de biomassa.

2.1 Objetivos específicos

- Criação de um banco de dados que englobe informações de diversas biomassas, incluindo as mais predominantes no sul do Brasil (casca de arroz, bagaço de cana-de-açúcar e madeira de pinus), bem como outras biomassas disponíveis na literatura.
- Prever os parâmetros cinéticos de gaseificação com uma base de dados mista (biomassas disponíveis na literatura e do sul do Brasil).
- Prever os parâmetros cinéticos de gaseificação de biomassa do sul a partir da base de dados de biomassas disponíveis na literatura.
- Avaliação do desempenho da rede neural artificial utilizando os parâmetros RMSE (erro quadrático médio) e o R^2 (coeficiente de determinação).

3 FUNDAMENTAÇÃO TEÓRICA

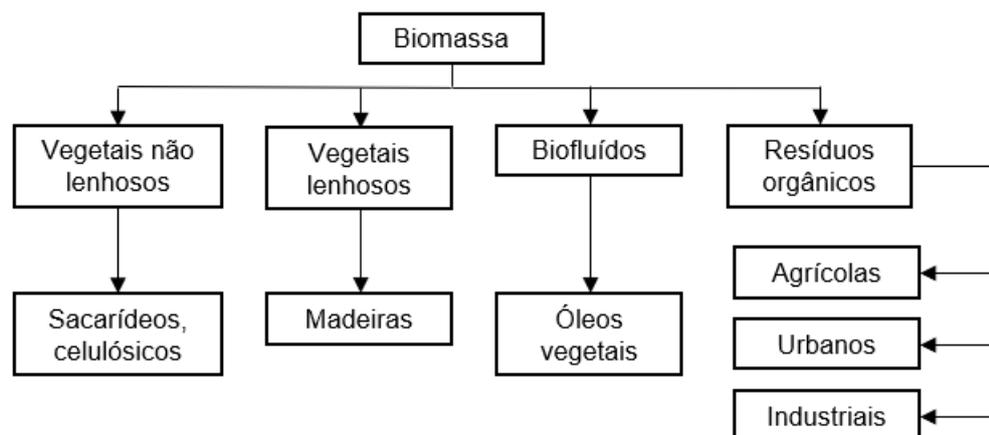
3.1 Biomassa

A biomassa é uma forma de energia solar capturada através da fotossíntese. É uma fonte crucial de energia ao longo da história e importante para países em desenvolvimento devido ao seu potencial (Castro e Dantas, 2008). Compreendendo matéria orgânica recente e biodegradável, originada de processos naturais e tecnológicos, a biomassa inclui plantas, animais, microrganismos, produtos e subprodutos da fotossíntese, resíduos agrícolas e florestais, além de rejeitos industriais e urbanos. Sua distinção dos combustíveis fósseis está na origem biológica e formação em um curto período (Pacioni, 2006).

A biomassa, como fonte competitiva de energia, tem o potencial de reduzir custos para o consumidor, emergindo como uma alternativa econômica e sustentável (Genovese; Udaeta; Galvão, 2006). Sua produção em regiões propícias não só impulsiona o desenvolvimento regional, gerando atividades econômicas, mas também promove o crescimento local (Dantas, 2016).

A utilização da biomassa na geração de energia é vantajosa em diversas esferas, incluindo ambiental, econômica e social. A Figura 1 ilustra as diversas fontes potenciais de biomassa.

Figura 1 - Fontes de biomassa



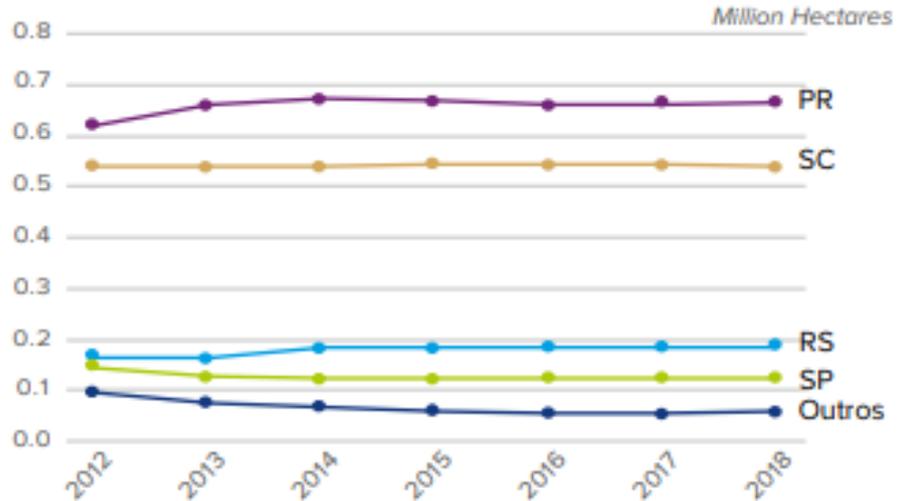
Fonte: Adaptado de Cortez *et al.* (2008)

Com base em gráficos e documentos disponibilizados pela Secretaria de Planejamento e Desenvolvimento Energético no Plano de Energia para 2030, é

possível constatar que as três biomassas mais utilizadas na região sul do Brasil são a madeira Pinus, o arroz e a cana-de-açúcar.

A Figura 2 evidencia a concentração da produção de Pinus, destacando a importância dessa biomassa na região sul, liderada pelos estados do Paraná, Santa Catarina e Rio Grande do Sul.

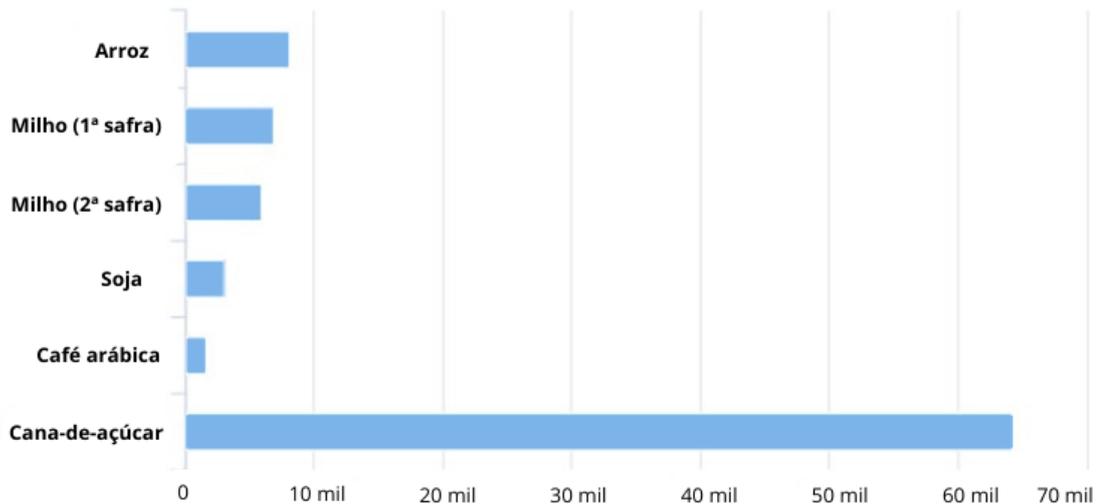
Figura 2 - Estimativa da produção sustentável em florestas plantadas Pinus por estado



Fonte: IBÁ (2018)

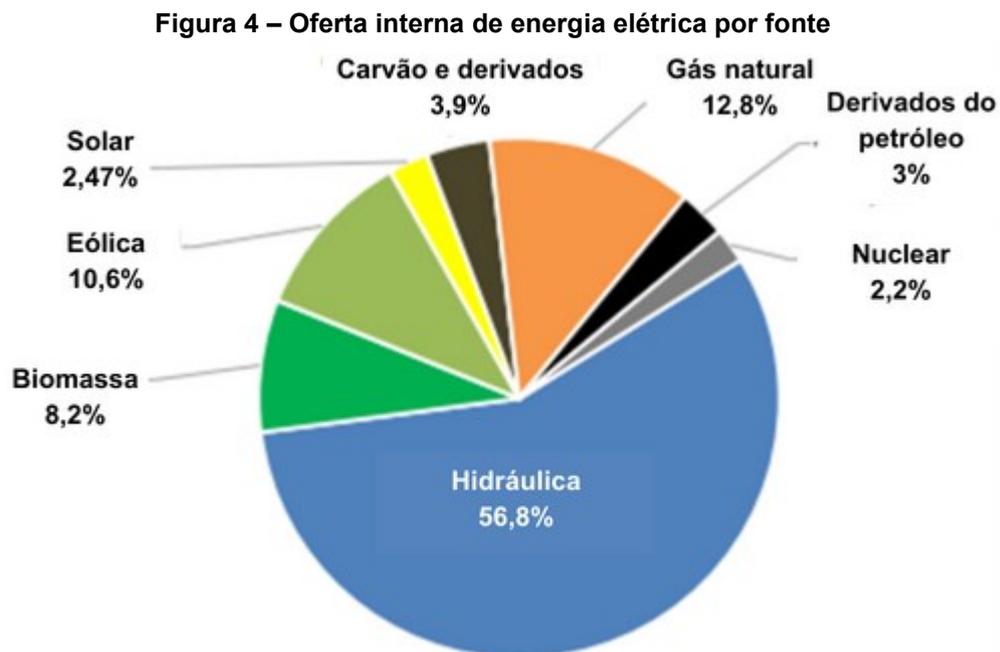
Já a Figura 3 mostra que o rendimento médio de quilo por hectare da produção de arroz e cana-de-açúcar é significativo na região, com o Rio Grande do Sul como maior produtor de arroz, de acordo com o IBGE (2023).

Figura 3 - Rendimento médio por ano da safra e produto na região sul do Brasil



Fonte: Adaptado de IBGE (2023)

A EMBRAPA (2022) destaca o Brasil como o maior produtor mundial de cana-de-açúcar, com significativa produção na região sul. A biomassa desempenha um papel crucial na matriz energética brasileira, sendo a terceira maior fonte de energia elétrica do país, como evidenciado no Balanço Energético Nacional de 2022 (Figura 4). Essa posição sublinha a importância do aproveitamento de resíduos orgânicos na geração de eletricidade.



Fonte: EPE (2022)

Em resumo, a escolha das três biomassas mais utilizadas no sul do Brasil - madeira de Pinus, cana-de-açúcar e arroz - para compor o conjunto de dados para o treinamento da rede neural artificial é relevante devido à sua disponibilidade regional, potencial energético e contribuição para a sustentabilidade e diversificação da matriz energética.

3.1.1 Análise elementar e imediata

A análise elementar da biomassa fornece uma porcentagem elemental mais precisa dos elementos carbono (C), o hidrogênio (H), o oxigênio (O), o nitrogênio (N), o enxofre (S), o cloro (Cl), que determina o rendimento de gás de síntese para a gaseificação (Mohamed, 2021). Esta análise é importante por trazer informações necessárias para o balanço de massa e de energia nos processos de conversões termoquímicas (Humberto *et. al.*, 2011).

A análise imediata fornece uma aproximação para o teor de carbono fixo, matéria volátil, cinzas e umidade da amostra (Mohamed, 2021). Cada uma dessas variáveis desempenha um papel importante na gaseificação. São especialmente relevantes para determinar a quantidade adequada de ar primário e secundário em reatores de leito fixo ou leito fluidizado, bem como para orientar os processos de ignição e as fases iniciais da combustão de sólidos, conforme destacado por Brand (2010).

O teor de carbono fixo em uma amostra reflete diretamente na quantidade de calor gerado durante a queima. Quanto mais elevado esse percentual, mais lenta será a queima do combustível, conforme observado por Vieira (2012). Combustíveis com altos índices de carbono fixo e baixa presença de voláteis tendem a queimar de maneira mais lenta, muitas vezes exigindo um período prolongado de residência no forno para alcançar uma queima total. Essa característica contrasta com outros combustíveis que possuem baixo teor de carbono fixo (Carvalho, 2022).

A matéria volátil representa entre 60 a 80% do peso da biomassa, e a maior parte é perdida durante a devolatilização, um processo caracterizado pela rápida liberação de voláteis, conferindo à biomassa uma alta reatividade (Demirbas, 2004).

O teor de cinzas na biomassa varia conforme a fonte e tem uma vantagem sobre o carvão devido ao seu baixo conteúdo de cinzas. A composição das cinzas difere entre diferentes biomassas, influenciando a sinterização e o amolecimento, fatores potencialmente prejudiciais ao processo (Jenkins *et al*, 1998). Assim, é essencial controlar as temperaturas de fusão de acordo com o tipo de biomassa para prevenir problemas como sinterização ou formação de escória, garantindo a eficiência e estabilidade do processo.

A umidade varia conforme o tipo de biomassa, estação do ano, clima e localização. Um elevado teor de umidade acarreta diversos efeitos adversos no processo de gaseificação, como complicações no manuseio e armazenamento, perda de matéria seca devido à decomposição, obstrução da entrada de alimentação, atrasos na ignição, maior consumo de energia e tempo para a ignição, além de atrasos na devolatilização. Adicionalmente, o alto teor de umidade reduz o valor calorífico do combustível. Esse excesso de umidade também resulta em um aumento no volume de gases de exaustão, exigindo dimensões maiores para os equipamentos (Demirbas, 2004).

3.1.2 Casca de arroz

O arroz, uma das culturas alimentares mais consumidas globalmente, representa aproximadamente 2% da produção global (EMBRAPA, 2022). Na região sul do Brasil, o arroz é um cultivo significativo, gerando um subproduto conhecido como casca de arroz durante o processo de beneficiamento do grão. Esta casca, representando cerca de 23% do peso do arroz, exibe uma textura dura e fibrosa. Apesar de seu baixo valor nutricional, a casca de arroz é caracterizada por sua resistência ao desgaste e alta concentração de cinzas (Miranda, 2013).

A utilização da casca de arroz como fonte de geração de energia não apenas apresenta uma perspectiva ética e ecológica, mas também se mostra viável devido à disponibilidade abundante dessa matéria-prima na região Sul (Foletto *et al.*, 2005). Além disso, é importante ressaltar que o dióxido de carbono (CO₂) gerado durante o processo é reintegrado ao ciclo natural, resultando em nenhum impacto ambiental negativo (Miranda, 2013).

3.1.3 Bagaço da cana-de-açúcar

A cana-de-açúcar, uma das culturas mais importantes no Brasil, coloca o país como líder mundial em sua produção, impulsionado pela crescente demanda por etanol. O Brasil se destaca nesse cenário devido às suas excelentes condições naturais, tecnológicas, climáticas e de solo para o cultivo (EMPRAPA, 2022).

Na região sul do Brasil, a produção de cana-de-açúcar desempenha um papel vital na geração de energia elétrica, principalmente por meio do aproveitamento do bagaço. Este subproduto, resultante da produção de açúcar e álcool, é empregado como combustível em caldeiras para gerar vapor, que, por sua vez, é convertido em energia elétrica (Moraes *et al.*, 2017). Além do aspecto energético, do ponto de vista financeiro, a produção de energia a partir do bagaço de cana-de-açúcar pode representar uma fonte suplementar de receita para as usinas sucroalcooleiras. Estas têm a capacidade de comercializar o excedente de eletricidade gerada para o sistema elétrico nacional, conforme destacado por Oliveira; Braga; Santos (2014).

3.1.4 Madeira Pinus

A madeira, composta principalmente pelo tecido xilemático, desempenha papéis cruciais nas árvores. Formado por diversas células especializadas, o xilema conduz a

seiva, transporta água e sais minerais, armazena substâncias e proporciona suporte estrutural à planta (Miranda, 2013). Segundo a Empresa de Pesquisa Energética (2020), a madeira Pinus é uma biomassa renovável com alto potencial energético devido ao seu teor de carbono fixo. Além disso, o cultivo de Pinus contribui para a preservação das florestas nativas, oferecendo uma alternativa sustentável para a obtenção de madeira.

A indústria moveleira gera uma quantidade significativa de resíduos de madeira durante a produção e descarte de móveis. Esses resíduos representam uma parte considerável do processo produtivo, e muitas fábricas estão explorando maneiras de utilizá-los como fonte de energia, seja para aquecimento das instalações ou para produção de eletricidade. No entanto, há um grande potencial para o aproveitamento mais eficiente e alternativo desses resíduos, visando reduzir os custos de disposição e minimizar os impactos ambientais (Derčan *et al.*, 2012). A madeira Pinus, dada sua abundância na região sul do Brasil, emerge como uma biomassa estratégica para a gaseificação.

3.2 Gaseificação

A gaseificação é uma tecnologia de conversão termoquímica que transforma combustíveis sólidos em produtos gasosos por meio de uma oxidação parcial controlada (Walawender *et al.*, 1985). Esta técnica desempenha um papel crucial na transformação da biomassa em gás de síntese (conhecido por *syngas*), um gás versátil utilizado como matéria-prima química ou como combustível para geração de calor ou eletricidade (Mohamed, 2021).

O processo de gaseificação acontece em 4 etapas: secagem, pirólise, oxidação/combustão e redução. A primeira etapa é a secagem, na qual a biomassa é aquecida no gaseificador, resultando na evaporação da água contida, o que leva a uma redução significativa do teor de umidade (Mohamed, 2021). Em seguida, temos a pirólise, uma etapa na qual a biomassa é submetida a altas temperaturas, resultando na decomposição térmica. Isso gera componentes gasosos como, H₂ e CO, sólidos como carbono ou carvão, e líquidos, incluindo alcatrão, água e hidrocarbonetos (Silva, 2021).

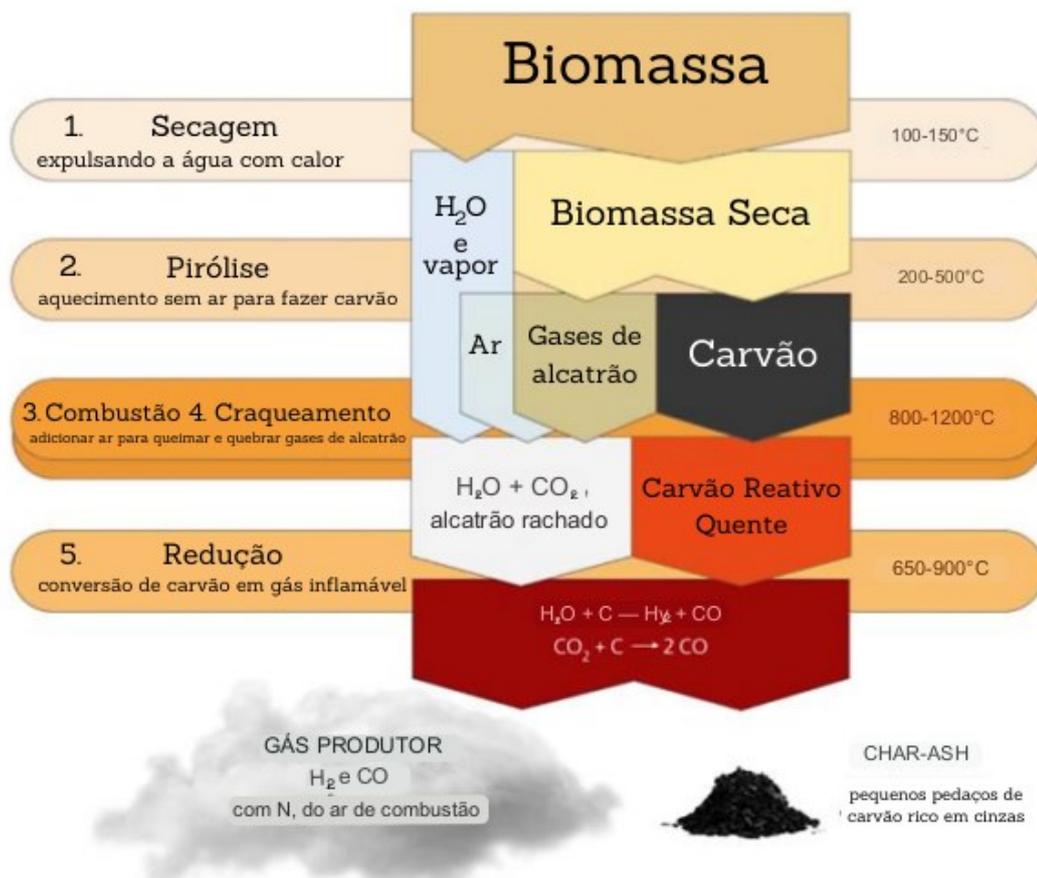
A terceira etapa, conhecida como oxidação ou combustão, ocorre em temperaturas que variam entre 1.100 e 1.500°C. Nesse processo exotérmico, o carbono e os produtos voláteis resultantes da pirólise sofrem uma oxidação parcial.

Esta etapa desempenha um papel crucial ao fornecer o calor necessário para as fases de secagem e pirólise, enquanto os principais subprodutos liberados incluem vapor d'água e dióxido de carbono, como indicado por Mohamed (2021).

Finalmente, na etapa de redução, as reações ocorrem na ausência de oxigênio, uma vez que o oxigênio foi consumido durante a oxidação. Essa fase acontece a temperaturas entre 800 e 1.000°C, e é caracterizada por reações específicas (Mishra; Upadhyay, 2021).

As etapas do processo de gaseificação podem ser visualizadas na ilustração a seguir:

Figura 5 – Etapas da gaseificação



Fonte: Adaptado de Mohamed (2021)

Os produtos resultantes da gaseificação passam por processos adicionais para a produção de diversos tipos de combustíveis como metanol, biocombustíveis por meio do processamento de Fischer-Tropsch, hidrogênio puro e metano. Esses produtos não só contribuem para combustíveis renováveis, mas também auxiliam no combate ao uso de combustíveis fósseis na indústria química. Existem diferentes tipos de gaseificadores utilizados nesse processo, desde os convencionais de fluxo ascendente ou descendente, até os modernos como os de plasma. Cada tipo de

gaseificador possui vantagens e desvantagens específicas (Akhtar; Krepl; Ivanova, 2018).

No processo de gaseificação, são utilizados agentes como ar, vapor de água, oxigênio ou uma mistura deles, em quantidades inferiores ao necessário para uma reação completa (Silva *et al.*, 2012). O Quadro 1, disposto a seguir, destaca as vantagens e dificuldades técnicas dos principais agentes de gaseificação amplamente utilizados.

Quadro 1 – Vantagens e desvantagens dos agentes de gaseificação

	Vantagens	Desvantagens
Ar	<ul style="list-style-type: none"> • Grande disponibilidade • Baixo custo de operação • Teor moderado de particulado e alcatrão, dependendo do tipo de gaseificador 	<ul style="list-style-type: none"> • Elevada concentração de N₂ • Baixo poder calorífico do gás produzido
Oxigênio	<ul style="list-style-type: none"> • Pode produzir gás com elevado poder calorífico • Reduzido teor de particulados e de alcatrão no gás produzido 	<ul style="list-style-type: none"> • Elevado custo de operação • Elevadas temperaturas de gaseificação • Necessidade de uma planta de separação do ar
Vapor	<ul style="list-style-type: none"> • Pode produzir gás com elevado poder calorífico • Produz gás com elevada concentração de H₂ 	<ul style="list-style-type: none"> • Necessita de uma fonte de aquecimento externa • Elevado custo de operação • Produz um gás com elevado teor de alcatrão

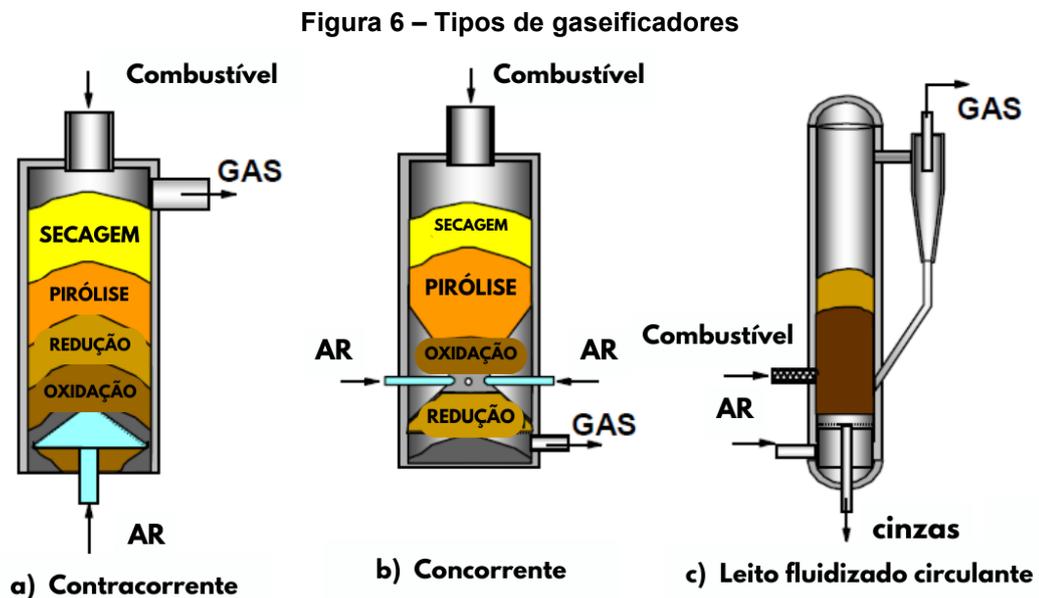
Fonte: Verisimo (2014)

3.2.1 Gaseificadores

O gaseificador desempenha um papel crucial na conversão termoquímica do material carbonáceo processado. Sua função é produzir um gás combustível limpo e de alta qualidade a partir de uma ampla variedade de combustíveis. Além disso, espera-se que o gaseificador opere de maneira eficiente, com pouca necessidade de atenção e capacidade de resposta rápida a mudanças na carga de trabalho. É importante também que o gaseificador possua um custo compatível e uma durabilidade adequada para atender às demandas de aplicação (Sánchez, 2010).

Uma classificação amplamente utilizada para os gaseificadores é baseada na direção do movimento relativo entre a biomassa e o agente de gaseificação. Essas classificações incluem gaseificadores de contracorrente, concorrente, fluxo cruzado e leito fluidizado (Sánchez, 2010). Cada tipo de gaseificador apresenta suas próprias características, vantagens e desvantagens.

Na Figura 6, pode-se identificar os diferentes tipos de gaseificadores, sendo: a) contracorrente; b) concorrente; e c) leito fluidizado circulante.



Fonte: Adaptado de SILVA *et al.* (2012)

O gaseificador contracorrente é conhecido por ser o tipo de construção mais simples. Nesse tipo de gaseificador, o ar é introduzido na parte inferior, com o fluxo ascendente dos gases, contrariamente ao fluxo de combustível que é inserido pela parte superior e desce devido à ação da gravidade à medida que é consumido na zona de combustão. Já no gaseificador concorrente, a alimentação é realizada através do topo, onde o combustível é introduzido. A entrada de ar ocorre no mesmo sentido do fluxo de combustível, passando pelas zonas de combustão e redução. Isso significa que tanto o combustível quanto o ar percorrem a mesma direção dentro do gaseificador, possibilitando a ocorrência dos processos de combustão e redução de forma simultânea (Sánchez, 2010).

Nos gaseificadores de leito fluidizado, as partículas de combustível são suspensas e fluidizadas utilizando um gás (agente gaseificante). Uma corrente de gás é introduzida na parte inferior do reator, fazendo com que as partículas formem um

leito com características semelhantes às de um fluido, conforme destacado por Grace *et al.* (2006).

No Quadro 2, disposto a seguir, são apresentadas as principais vantagens e desvantagens dos gaseificadores de leito fixo e de leito fluidizado.

Quadro 2 – Vantagens e desvantagens dos gaseificadores de leito fixo e fluidizado

Leito fixo concorrente ("downdraft")	
Vantagens	Desvantagens
Construção relativamente simples e seguro	Requer baixa umidade do combustível a ser utilizado
Gás produzido relativamente limpo	Restrição de granulometria do material a ser utilizado como combustível (não pode ser muito pequeno)
Alto potencial para conversão de carbono	Alta temperatura do gás produzido (saída)
Pouco arraste de cinzas	Possibilidade de fusão das cinzas devido as altas temperaturas de operação
Alta eficiência de conversão	
Leito fixo contracorrente ("up draft")	
Vantagens	Desvantagens
Construção muito simples e robusta	Gás produzido muito sujo e com alto teor de alcatrão
Baixa temperatura dos gases de saída	Devido o gás produzido ser muito sujo, não se adequa ao uso com motores de combustão interna por necessitar de um sistema de limpeza muito caro.
Alta eficiência térmica	
Alta conversão de carbono	
Pouco arraste de doenças	
Alto tempo de residência dos sólidos	
Produz gás adequado para queima direta	
Desligamento fácil	
Excelente eficiência de conversão	
Leito fluidizado ("fluidized bed")	
Vantagens	Desvantagens
Tolera variações da qualidade do combustível	Sistema de alimentação
Grande tolerância à granulometria do combustível	Pode haver aglomeração do leito
Bom controle da temperatura do leito	Demora na partida
Rápida resposta a carga	Não é de operação trivial
Excelente distribuição da temperatura do leito	Alta concentração de particulados no gás produzido
Possibilidade de processo catalítico no leito	Perda de carbono com as cinzas
Níveis moderados de alcatrão no gás produzido	
Pode operar a carga parcial	
Alta eficiência de conversão	

Fonte: Silva et al (2012)

3.2.2 Modelos e parâmetros cinéticos

Modelo cinético é uma representação matemática que descreve o comportamento de um processo cinético; é uma ferramenta fundamental para

entender e descrever a conversão de biomassa durante a gaseificação, sendo crucial no projeto, avaliação e aprimoramento de gaseificadores (Yang; Chen, 2015).

Compreender o mecanismo cinético da gaseificação de biomassa para projetar o reator e operação dos sistemas de gaseificação permite alcançar uma conversão de energia ideal, maximizando a eficiência do processo (Wang; Kinoshita, 1993); além de ser essencial para compreender os mecanismos envolvidos e para projetar o reator (Alves *et al.*, 2016).

Um dos parâmetros mais importantes no estudo cinético é a energia de ativação (E_a) de uma reação química, que é uma variável cinética que representa a energia mínima necessária para que ocorra uma reação entre moléculas. Ainda, outro parâmetro muito importante é o fator de frequência ou fator pré-exponencial (A), que está relacionado ao número total de colisões entre as espécies químicas por unidade de tempo e volume. Ele representa a frequência com que as moléculas reagentes se encontram em uma posição e orientação adequadas para que ocorra uma reação (Silveira, 2015).

Os parâmetros dos modelos cinéticos são obtidos em laboratório, por meio de experimentos. Uma técnica muito utilizada para a determinação de parâmetros cinéticos em batelada para reações térmicas é a análise termogravimétrica (“*thermogravimetric analysis*” ou TGA, na sigla em inglês). Os experimentos em TGA envolvem o aquecimento controlado da biomassa para determinar as taxas de decomposição térmica em diferentes condições de temperatura e atmosfera (Rajisha *et al.*, 2011). Os dados resultantes do TGA são utilizados para ajustar os parâmetros dos modelos cinéticos, permitindo uma melhor descrição e previsão das reações de conversão durante a gasificação da biomassa.

O modelo de redes neurais artificiais (RNA) é uma abordagem que se destaca na previsão dos parâmetros de gaseificação por ser não mecanicista, desprovido de equilíbrio e não analítico. Trata-se de uma modelagem empírica que não exige um profundo entendimento dos fenômenos internos que ocorrem do reator. Embora não forneça informações detalhadas sobre o funcionamento do sistema, as redes neurais artificiais têm a capacidade de prever de maneira precisa, por exemplo, a composição de saída do gaseificador (Ajourloo *et al.*, 2022).

A Figura 7, ilustra uma comparação do modelo de RNA com outras abordagens, incluindo o equilíbrio químico, o modelo cinético e o modelo de fluidodinâmica

computacional, oferecendo uma visão mais completa das vantagens e limitações de cada um dos modelos.

Figura 7 – Comparação entre modelos

Redes Neurais Artificiais	Modelos Cinéticos	Equilíbrio Químico	Equilíbrio Termodinâmico
<ul style="list-style-type: none"> • Uma abordagem de modelagem matemática • Faz uso de regressão para correlacionar fluxos de entrada e saída • Mostra boa precisão na previsão de composição • Menos conhecimento dos fenômenos do sistema • É necessário um grande número de dados experimentais • Não fornece resultados analíticos 	<ul style="list-style-type: none"> • Inclui cinética de reação, hidrodinâmica do sistema, distribuição de tamanho de partícula • Prevê a composição do gás e os perfis de temperatura ao longo do comprimento do reator • Resultados precisos mesmo em baixas temperaturas • Computacionalmente intensivo • Sensível ao processo de contato gás-sólido 	<ul style="list-style-type: none"> • Baseado em equações de conversão de massa, calor e momento • Previsão altamente precisa sobre o rendimento do gás de síntese • Fornece perfis de temperatura e concentração • Bom para projeto de reatores e solução de problemas • Difícil de implementar devido à complexidade do processo de gaseificação • Computacionalmente intensivo 	<ul style="list-style-type: none"> • Simples e fácil de implementar e independente do projeto do gaseificador • Aproximação convincente da composição do gás de síntese e previsão dos rendimentos máximos alcançáveis • Uma ferramenta prática para análise de sensibilidade • Não há necessidade de reações químicas e mecanismos de conversão • O estado de equilíbrio pode não ser alcançado, especialmente sob baixas temperaturas operacionais • Subestimação excessiva de espécies de gases • Muitas suposições simplificadoras

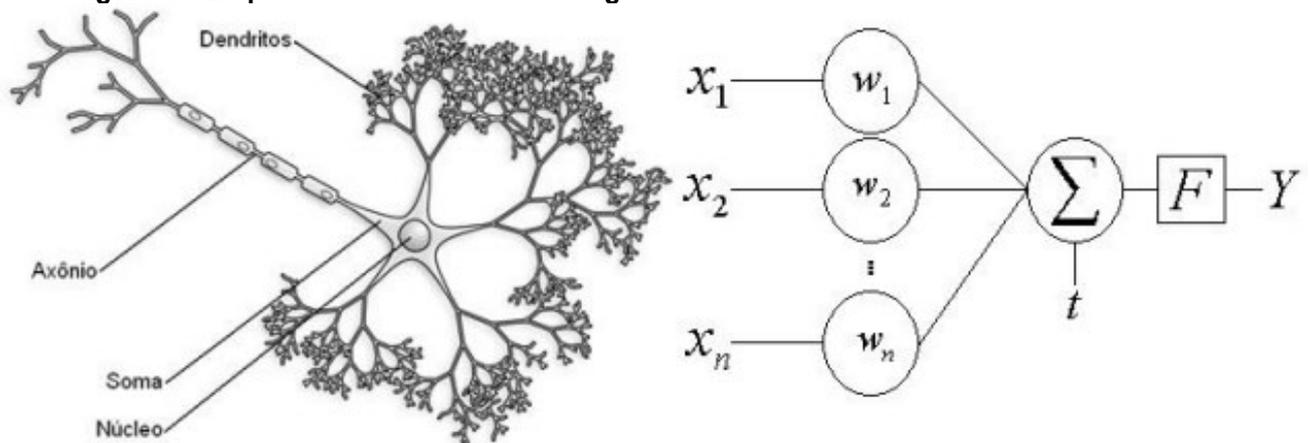
Fonte: Adaptado de Ajourloo (2022)

3.3 Redes neurais artificiais

A Inteligência Artificial (IA) é uma tecnologia amplamente utilizada em várias áreas, buscando automatizar problemas complexos. Entre as técnicas utilizadas, destacam-se as redes neurais artificiais (RNAs), que são capazes de classificar, agrupar, reconhecer e prever padrões (Wirtz *et al.*, 2019).

As redes neurais artificiais são um tipo de processamento de informações que imitam o funcionamento do cérebro humano. A principal característica das redes neurais é a sua capacidade de aprender a partir de dados de entrada e inferir funções a partir dessas observações. Elas são compostas por unidades de processamento simples que armazenam conhecimento experimental e o tornam disponível para uso (Haykin, 2001).

Figura 8 – Esquema de um neurônio biológico e de um modelo de neurônio artificial



Fonte: Duarte (2010)

O conceito central do paradigma das redes neurais é criar um modelo formado por um grande número de unidades de processamento simples, conhecidas como neurônios, que estão conectadas entre si por múltiplas conexões. Os neurônios são responsáveis pelo processamento das informações. A transmissão das informações ocorre por meio das conexões, também chamadas de sinapses ou pesos sinápticos (Santos *et al.*, 2005).

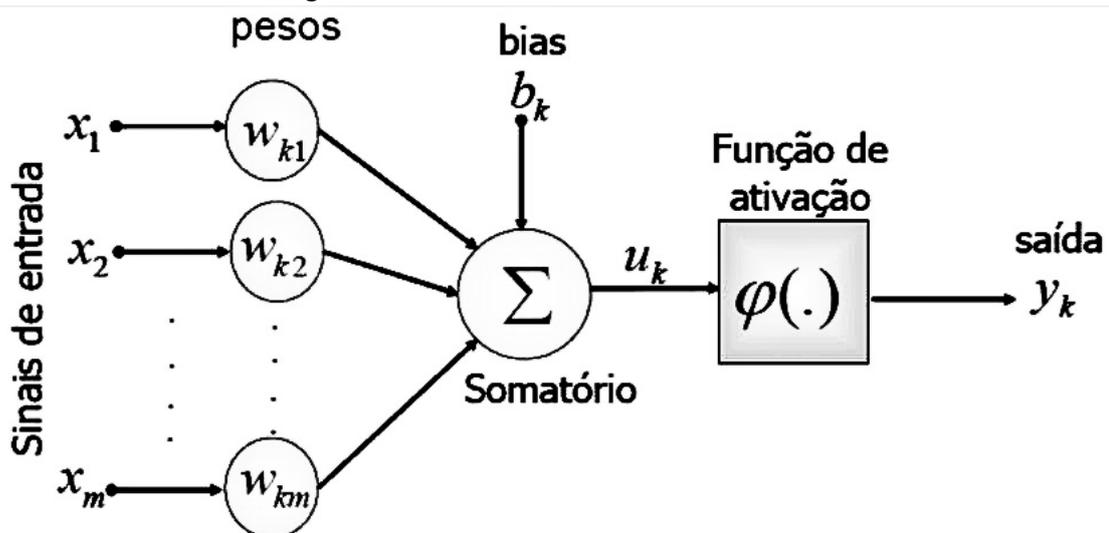
As aplicações das redes neurais artificiais (RNAs) para resolver problemas do mundo real abrangem diversos campos científicos, desde finanças até hidrologia, e podem ser categorizadas em três grupos principais: (i) classificação de padrões, (ii) previsão e (iii) controle e otimização (Malekian; Chitsaz, 2021). Este trabalho está inserido na categoria de previsão, pois o objetivo é realizar previsões dos parâmetros cinéticos da gaseificação das biomassas utilizando RNAs.

3.3.1 Estrutura de uma rede neural

Uma rede neural multicamadas é composta por várias camadas de neurônios organizadas em sequência. Na estrutura dessa rede, a camada inicial é denominada camada de entrada, na qual as informações iniciais são inseridas. Essa camada transmite essas informações para uma ou mais camadas intermediárias, conhecidas como camadas ocultas. O número de camadas ocultas pode variar de acordo com a complexidade do problema. Por fim, tem-se a camada de saída, responsável por gerar a solução final do problema. Essa arquitetura em camadas permite que a rede neural processe e transforme as informações gradualmente, facilitando a extração de padrões e a tomada de decisões (Santos *et al.*, 2005).

De acordo com Braga *et al.* (2012), um modelo básico de RNA (Rede Neural Artificial) é composto por vários elementos essenciais. Entre eles, destaca-se o conjunto de sinapses, que são as conexões estabelecidas entre os neurônios da RNA. Cada sinapse possui um peso sináptico associado, determinando a importância relativa daquela conexão. Além disso, tem-se o integrador, que realiza a soma dos sinais de entrada ponderados pelos pesos sinápticos, e a função de ativação, que restringe a amplitude do valor de saída de um neurônio por meio de uma transformação não-linear. Por fim, tem-se o bias, um valor externo aplicado a cada neurônio, que ajusta a entrada líquida da função de ativação. Esses componentes desempenham um papel fundamental no funcionamento e processamento de informações em uma RNA.

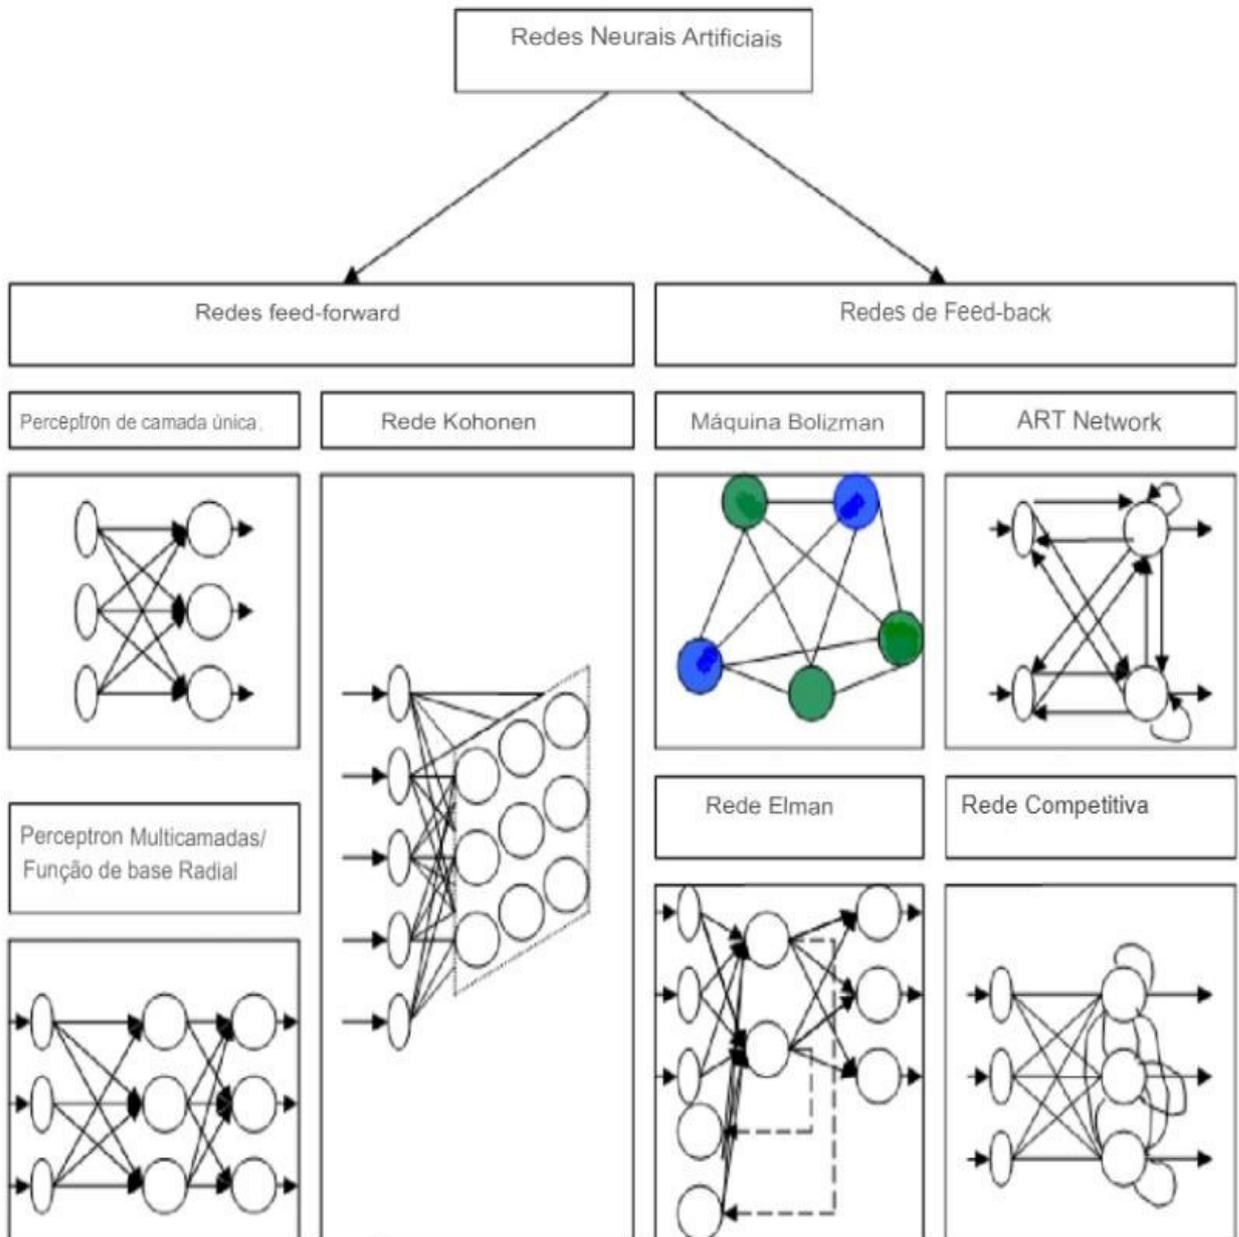
Figura 9 – Elementos da rede neural artificial



Fonte: Adaptado de Haykin (2001)

As redes neurais podem ser divididas em duas classes principais com base em sua topologia: redes de alimentação direta (*feed-forward*) e redes de realimentação (*feedback*). As redes de alimentação direta incluem exemplos como perceptrons de uma ou várias camadas, redes de função básica radial e rede Kohonen. Por outro lado, as redes de realimentação englobam redes competitivas, rede de teoria de ressonância adaptativa (ART), rede parcialmente recorrente e rede totalmente recorrente, entre outros exemplos (Rashid; Kechadi, 2006). A Figura 9 apresenta uma visualização dos diversos tipos de arquiteturas de redes neurais artificiais.

Figura 10 – Diferentes tipos de arquitetura de redes neurais artificiais



Fonte: Adaptado de Rashid (2006)

3.3.2 Feed-forward

A rede neural artificial do tipo feed-forward foi o primeiro tipo de rede neural inventado, sendo a rede mais simples quando comparada a outros modelos, como as redes recorrentes (Sharkawy, 2020). É chamada de "feed-forward" porque a informação viaja apenas em uma direção na rede (sem ciclos), primeiro passando pelos nós de entrada, depois pelos nós ocultos (se presentes), e, por fim, pelos nós de saída (Sharkawy, 2020).

As redes feed-forward, apresentam várias vantagens em muitos cenários de aplicação. Sua estrutura simples facilita a implementação e compreensão, tornando-as acessíveis a uma ampla gama de usuários (Haykin, 2001). Apresenta bom desempenho em diversos casos de previsão, sendo uma rede robusta que pode ser aplicada facilmente e com sucesso em vários domínios de problemas (Schmidhuber, 2015).

Outras características destacadas dessa rede incluem sua habilidade para realizar a aproximação de funções complexas e sua capacidade de fazer previsões tanto de valores contínuos quanto discretos (Otchere et al., 2021).

Atualmente, as opções para desenvolvimento de RNAs são amplamente acessíveis, com uma variedade de ferramentas disponíveis para facilitar o desenvolvimento desses modelos. Linguagens de programação como Python, C++, frameworks como Tensorflow do Google, Theano, Matlab e plataformas como Spark disponibilizam um conjunto robusto de operações matemáticas essenciais para a construção de RNAs (Abdolrasol *et al.*, 2021).

Com base nas vantagens mencionadas anteriormente, esta pesquisa adotará uma abordagem utilizando uma rede neural artificial do tipo feed-forward para a determinação de parâmetros cinéticos de gaseificação de biomassas amplamente utilizadas na região sul do Brasil.

3.4 Estado da arte

No Quadro 3 são apresentados estudos correlacionados com o presente trabalho de pesquisa. Esta análise fará uma revisão vasta da literatura existente, destacando lacunas de conhecimento.

Quadro 3 – Estudos correlacionados

Trabalho	Autor	Resumo	Conclusão
Modelo de rede neural artificial para a previsão de parâmetros cinéticos da pirólise de biomassa a	Sunphor ka <i>et al.</i> (2017)	Propuseram redes neurais artificiais (RNA) para estabelecer correlações entre os constituintes da biomassa e os parâmetros cinéticos da pirólise. Três modelos de RNA foram desenvolvidos para prever esses parâmetros. Foram utilizadas 150 análises	Os modelos de RNA selecionados demonstraram alta precisão na previsão dos parâmetros, com coeficientes de determinação (R^2) superiores a 0,9.

partir de seus constituintes.		termogravimétricas experimentais de várias composições de biomassa.	
Avaliação de desempenho da eficiência de sistemas de gaseificação usando redes neurais artificiais.	Ozonoh <i>et al.</i> (2020)	Investigou a utilização redes neurais para prever a composição dos gases produzidos durante a gaseificação de biomassa para geração de energia. Com base em 315 experimentos com diferentes tipos de biomassa e condições de processo	Os modelos de rede neural apresentaram R^2 variando de 0,79 a 0,98 para as entradas e de 0,95 a 0,96 para as saídas. Além disso, foi observado que o teor de carbono desempenha um papel fundamental na previsão da eficiência da gaseificação.
Um modelo abrangente de rede neural artificial para previsão do processo de gasificação.	Ascher <i>et al.</i> (2022)	O autor utilizou dados de entrada abrangentes, incluindo Análise Fundamental, Análise aproximada, composição lignocelulósica, informações sobre a matéria prima, condições e informações sobre o gaseificador. O objetivo era prever as saídas, que consistiam na Composição do <i>Syngas</i> , no Rendimento e na Eficiência do Processo. Para isso, desenvolveu um modelo de rede neural artificial	RNA com precisão de previsão de $R^2 = 0.9310$ e $RMSE = 0.1307$ para modelar a gasificação de biomassa e resíduos.
Modelagem do processo de gaseificação de biomassa empregando redes neurais	Nemer (2010)	Investigar a correlação entre as características da biomassa e a composição do gás produzido no processo de gaseificação através do uso de redes neuronais artificiais	As redes neurais artificiais do tipo MLP, ou <i>Perceptron</i> de Múltiplas Camadas, representam uma perspectiva promissora para modelar o processo de gaseificação de biomassa. Contudo, o potencial de melhoria na capacidade de previsão dessas redes poderia ser explorado através da expansão do conjunto de dados experimentais de treinamento
Comparação das diferentes redes neurais artificiais na	Yucel <i>et al.</i> (2019)	Neste estudo, foram empregadas redes neurais artificiais (RNAs) e um modelo de rede neural auto-regressivo não linear com	Os resultados dos modelos de RNAs foram consistentes com os dados experimentais, tendo o $R^2 > 0,99$.

previsão dos produtos da gasificação de biomassa.		entradas exógenas (NARX) para modelar a gaseificação em leito fixo do tipo <i>downdraft</i> . Dados experimentais de 3831 amostras de dados pertencentes a pellets de madeira foram usados para treinar as RNAs. O objetivo foi a previsão dos produtos da gaseificação de biomassa	
Um modelo de rede neural recorrente para a química da gaseificação de biomassa.	Sharma et al. (2022)	Neste trabalho, foi desenvolvido um modelo de rede neural recorrente (RNN) para as reações gasosas secundárias da gasificação de biomassa em um ambiente inerte na faixa de temperatura de 800 a 1000 °C.	O modelo de RNN baseado em GRU (<i>Gated Recurrent Unit</i>) desenvolvido neste estudo demonstrou sua capacidade de prever com precisão a evolução temporal de reagentes e produtos durante a gasificação de biomassa em uma ampla faixa de condições de reator. Além disso, o modelo foi eficaz na redução do custo computacional em comparação com o esquema cinético de referência

Fonte: Autoria própria (2023)

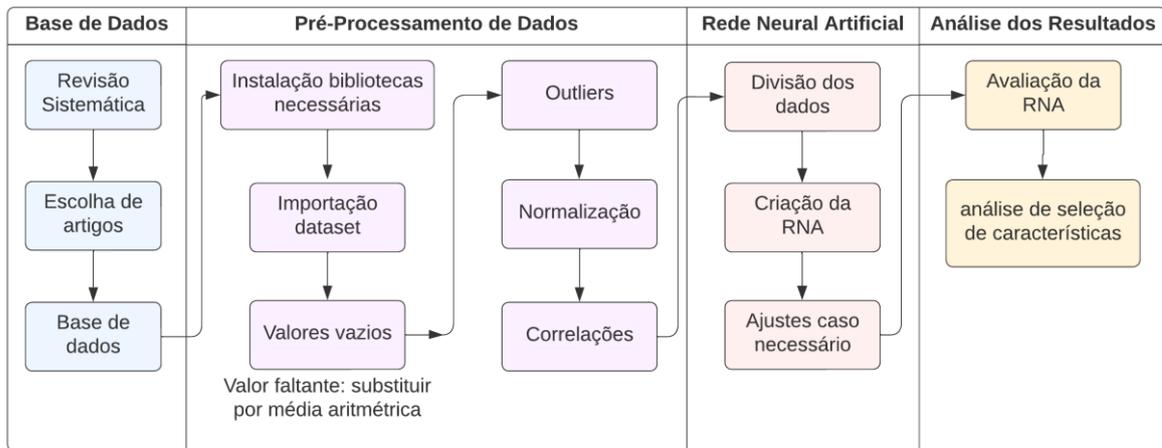
Apesar dos avanços alcançados por esses estudos, até o momento, nenhum deles abordou especificamente a determinação de parâmetros cinéticos de gaseificação de biomassas utilizando redes neurais artificiais. Portanto, há uma lacuna na literatura para investigar e desenvolver modelos que sejam capazes de prever com precisão os parâmetros cinéticos como a energia de ativação e o fator pré-exponencial.

4 PROCEDIMENTOS METODOLÓGICOS

Nesta seção, são detalhadas as etapas metodológicas adotadas na presente pesquisa para a determinação dos parâmetros cinéticos de gaseificação de biomassa por meio de redes neurais artificiais. A metodologia empregada foi dividida em quatro etapas principais, a saber: seleção da base de dados, pré-processamento dos dados, criação da rede neural e análise dos resultados.

De maneira ilustrativa, é possível visualizar por meio do fluxograma mostrado na Figura 11 as diversas etapas metodológicas empregadas neste trabalho.

Figura 11 – Fluxograma dos procedimentos metodológicos



Fonte: Autoria própria (2023)

4.1 Base de dados

Foi conduzida uma revisão sistemática da literatura em fontes de pesquisa, incluindo SCOPUS, Science Direct e Google Acadêmico, com o objetivo de selecionar artigos que fornecessem dados para a análise imediata e análise elementar de biomassas, além dos parâmetros cinéticos relacionados à gaseificação destes combustíveis sólidos. A escolha dessas fontes baseou-se em sua abrangência e qualidade reconhecidas no campo científico.

Os critérios de inclusão para os artigos selecionados foram:

- Estar disponíveis nas fontes de pesquisa de forma gratuita.
- Possuir pelo menos uma das biomassas necessárias, sendo elas biomassas específicas da região sul do Brasil, como casca de arroz, bagaço de cana-de-açúcar e madeira Pinus, além de biomassas em geral.

- Possuir pelo menos um parâmetro cinético de gaseificação de biomassa (energia de ativação ou fator pré-exponencial).

Os critérios de exclusão:

- Dados cinéticos de outros processos termoquímicos.
- Não gratuidade do artigo.

As palavras-chave utilizadas na pesquisa da revisão sistemática foram:

- *Gasification and kinetic or kinetics and pine and wood*;
- *Gasification and kinetic or kinetics and rice husk*;
- *Gasification and kinetic or kinetics and sugar cane bagasse*;
- *Gasification and kinetic or kinetics and biomass*;

O total de artigos encontrados para cada uma das biomassas em todos os meios de pesquisa, foram de:

- Bagaço de cana de açúcar: 36 artigos
- Madeira Pinus: 127 artigos
- Casca de arroz: 101 artigos
- Biomassas diversas: mais de 100 mil artigos

Diante da vasta quantidade de artigos disponíveis sobre diversas biomassas, tornou-se impraticável examinar todos os resultados. Com o intuito de otimizar o processo de análise, foi adotada uma abordagem, selecionando os primeiros 150 artigos para uma avaliação mais detalhada.

A lista resultante de artigos foi submetida a uma análise cuidadosa, verificando se continham os dados necessários para este trabalho. É relevante ressaltar que a qualidade e quantidade dos dados coletados nesta etapa impactam diretamente a eficácia do treinamento e, conseqüentemente, a precisão da rede (Goodfellow *et al.*, 2016). Todos os artigos selecionados foram registrados e organizados em uma planilha – Apêndice A - para passar pela etapa de pré-processamento de dados.

Como parte desse processo, dois conjuntos distintos de dados foram criados. O primeiro reúne informações específicas sobre as biomassas mais amplamente utilizadas na região sul do Brasil, sendo elas a madeira Pinus, casca de arroz e bagaço de cana-de-açúcar. O segundo conjunto engloba dados relacionados a biomassas de diversas origens, selecionadas a partir da revisão sistemática da literatura científica, complementando assim a base de dados de maneira abrangente e diversificada.

4.2 Pré-processamento de dados

Para a condução deste trabalho, optou-se pelo ambiente computacional Google Colab, utilizando a linguagem de programação Python. A escolha do Google Colab se baseou na sua facilidade de colaboração e na disponibilidade de recursos computacionais, enquanto o Python foi escolhido devido à sua gama de bibliotecas voltadas para aprendizado de máquina. O equipamento utilizado durante todo o desenvolvimento do projeto consistiu em um notebook equipado com processador Intel Core i7 8565U CPU e 16 GB de RAM.

Na etapa inicial de pré-processamento dos dados, as bibliotecas essenciais foram importadas, e o conjunto de dados foi carregado. Adotaram-se técnicas específicas para garantir a qualidade e uniformidade dos dados.

Para lidar com os valores ausentes, foi utilizada a técnica de imputação de média aritmética, a qual consiste na substituição dos valores ausentes pela média da variável, calculada a partir dos valores válidos presentes na amostra (Vinha; Laros, 2018), sendo considerada uma abordagem de aplicação simples e eficaz (Bleidorn *et al*, 2022).

Para a remoção de outliers, foi utilizado o método de Tukey, mais conhecido como Boxplot, que utiliza o Intervalo Interquartil (IQR) para definir limites inferior e superior com base nos quartis. O IQR é a diferença entre o terceiro quartil (Q3) e o primeiro quartil (Q1) (Rousseeuw; Hubert, 2017).

$$IQR = Q3 - Q1 \quad (1)$$

É utilizado um fator de 1,5 sobre o IQR para determinar os limites a partir das equações abaixo:

$$Linf = Q1 - (1.5 * IQR) \quad (2)$$

$$Lsup = Q3 + (1.5 * IQR) \quad (3)$$

Assim, qualquer valor obtido fora deste intervalo ($Q1 < x < Q3$), é considerado um outlier. O IQR é uma medida que descreve a dispersão dos dados em torno da mediana. Ele é menos afetado por valores discrepantes, tornando-o uma ferramenta mais útil na análise estatística (Nascimento *et al*, 2021).

No processo de normalização, adotou-se o método Z-score, que expressa cada valor em termos de quantos desvios padrões ele está acima ou abaixo da média. Esta técnica proporciona uma medida de relativa distância em relação ao padrão médio (De Lira, 2020).

A etapa final do processamento inicial dos dados envolveu a criação da matriz de correlação de Pearson a partir dos dados já pré-processados. Com a obtenção da matriz é possível descobrir até que ponto as variáveis estão correlacionadas, revelando a natureza e a intensidade da interdependência, especialmente quando essa relação não é facilmente compreendida de imediato (Araujo *et al*, 2019).

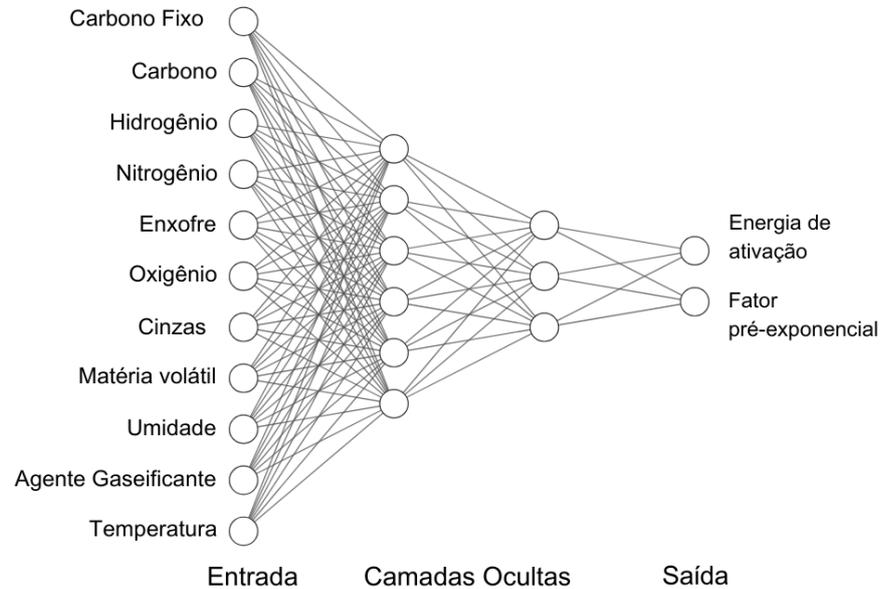
Foi gerado um único conjunto de dados para todos os testes, sendo as variações apenas na distribuição entre os conjuntos de treinamento e teste. Devido à realização da divisão do conjunto ocorrer somente após o pré-processamento, a matriz de correlação de Pearson será igual em todos os testes, assim como a preservação do número de valores nulos, normalização e detecção de outliers.

4.3 Rede neural artificial

Na implementação da rede neural artificial, optou-se pela arquitetura feed-forward devido à sua simplicidade e eficácia em problemas de regressão, conforme visto anteriormente. Os conjuntos de dados foram divididos em treinamento e teste, sendo o primeiro utilizado para ajustar os parâmetros da rede, enquanto o segundo avalia o desempenho em condições reais, evitando distorções na avaliação da capacidade de generalização (Santos *et al.*, 2005).

Os dados de entrada foram escolhidos com base em especificações do reator, resultados das análises imediata e elementar das biomassas (abrangendo percentuais de material volátil, cinzas, umidade, carbono fixo, carbono, oxigênio, hidrogênio, nitrogênio, enxofre), tipo de agente gaseificante (dióxido de carbono, vapor de água e oxigênio) e temperatura de gaseificação. Os dados de saída correspondem à análise dos dados cinéticos fundamentais da gaseificação da biomassa, sendo eles a energia de ativação e fator pré-exponencial.

Na Figura 12, é possível visualizar uma representação do modelo de rede neural artificial do tipo feed-forward desenvolvido neste trabalho, destacando as camadas ocultas, entradas e saídas desejadas.

Figura 12 – Rede neural artificial

Fonte: Autoria própria (2023)

Foram exploradas diferentes porcentagens para alocar dados nos conjuntos de treinamento e teste, conforme apresentado no Quadro 4.

Quadro 4 – Configuração de treinamento e teste

Treinamento	Teste
80%	20%
75%	25%
70%	30%

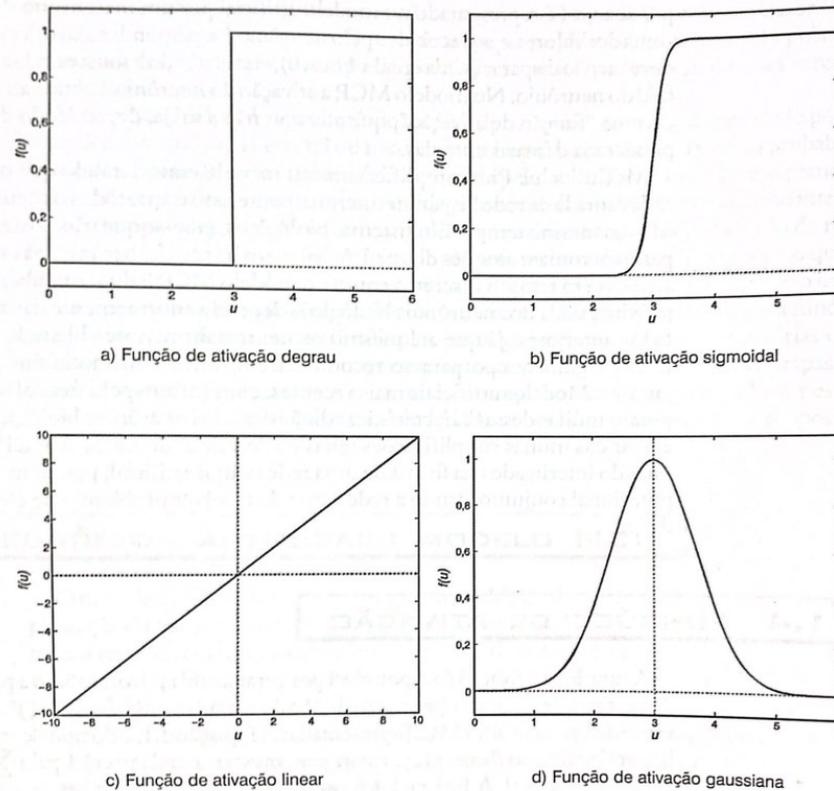
Fonte: Autoria própria (2023)

No decorrer do processo de treinamento, as redes neurais ajustam as relações entre neurônios por meio de valores denominados pesos, que funcionam como coeficientes multiplicativos. O propósito do treinamento é aprimorar esses pesos, de forma a reduzir ao máximo a diferença entre a saída da rede e o resultado desejado, aperfeiçoando a habilidade da rede em fazer previsões precisas (Goodfellow *et al.*, 2016). Para atingir esse fim, realizamos uma busca por melhores pesos, utilizando sementes (*seeds*) que variaram de zero até cem mil.

Diversas funções de ativação foram consideradas, como a função limiar, a função linear por partes, a função sigmoidal, função tangente hiperbólica e função gaussiana. Cada uma dessas funções possui características distintas e é escolhida de acordo com a natureza do problema a ser resolvido (Braga *et al.*, 2012). A escolha

dessas funções foi orientada pelo livro *Redes neurais artificiais teorias e aplicações* de Braga *et al.* (2012), conforme ilustrado na Figura 13.

Figura 13 – Rede neural artificial



Fonte: Braga et al (2012)

Foi empregado o otimizador Adam, um método de otimização que ajusta as taxas de aprendizado de forma adaptativa para cada parâmetro. Atualmente, ele é reconhecido como um dos métodos de otimização mais populares para treinar redes neurais artificiais (Ribeiro; Araujo, 2020). O otimizador mantém controle sobre dois vetores de atualização com base no gradiente:

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) \cdot g_t \quad (4)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) \cdot g_t^2 \quad (5)$$

Onde m_t é a estimativa da média, v_t a variação não centralizada dos gradientes, β_1 e β_2 as taxas de decaimento e g_t o gradiente em relação aos parâmetros no tempo. Sendo assim, a equação para atualização dos pesos para o otimizador Adam é demonstrada na Equação 6:

$$\theta_{t+1} = \theta_t - \frac{n}{\sqrt{\hat{v}} + \varepsilon} \cdot \hat{m}_t \quad (6)$$

Onde θ são os parâmetros no tempo, n é a taxa de aprendizado e ϵ um termo de suavização.

Com o objetivo de obter o maior valor possível para o coeficiente de determinação (R^2) na predição dos dados de saída, foram testados diferentes parâmetros – funções de ativação, busca por pesos, diferentes conjuntos de camadas ocultas, taxa de aprendizado, número de épocas e tamanho de lotes – com o intuito de encontrar a melhor configuração para a rede neural, conforme ilustrado no Quadro 5.

Quadro 5 – Variações de parâmetros

Parâmetros	Variações
Camadas ocultas	Camadas únicas indo de 1 a 10 neurônios e camadas duplas com diversas combinações: [2, 4], [4, 6], [6, 8], [8, 10], [4, 2], [6, 4], [8, 6], [10, 8], [3, 5], [5, 3], [10, 6], [10, 4], [6, 2], [4, 4], [2, 2], [6, 6], [8, 8]
Funções de ativação	Função de ativação degrau, sigmoidal, relu, linear, tangente hiperbólica e gaussiana
Épocas	Variando do zero até o mil, em intervalos iguais de 50 (0, 50, 100, ..., 950, 1000).
Tamanho de lotes	Variando de 2 a 200, apenas números pares. Depois foi adicionado os seguintes números ímpares (50, 75, 175).

Fonte: Autoria própria (2023)

4.4 Análise dos resultados

A avaliação dos resultados da rede neural compreendeu a análise de sua precisão em relação aos conjuntos de dados de treinamento e teste.

Para quantificar a precisão da rede neural, foram adotadas métricas como o RMSE (erro quadrático médio) e o R^2 (coeficiente de determinação). O RMSE mede a diferença média entre os valores reais e os valores previstos pela rede neural, onde o melhor valor que pode ser obtido é zero. A Fórmula 4 disposta a seguir mostra como este parâmetro foi calculado.

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (x_i - y_i)^2} \quad (4)$$

Onde $RMSE$ é o erro quadrático médio, m é o número total de observações no conjunto de dados, x_i é o valor real da variável e y_i é o valor previsto.

Já o R^2 fornece uma indicação da proporção da variabilidade dos dados que pode ser explicada pelo modelo. Onde o melhor valor é 1 e o pior vai até infinito negativo (Chicco *et al*, 2021).

$$R^2 = 1 - \frac{\sum_{i=1}^m (x_i - y_i)^2}{\sum_{i=1}^m (\bar{y} - y_i)^2} \quad (5)$$

Onde R^2 é o coeficiente de determinação.

5 RESULTADOS

Foram realizados dois testes principais para a determinação dos parâmetros cinéticos da gaseificação de biomassa, proporcionando uma avaliação abrangente e outra específica para a região sul do Brasil.

No primeiro teste, o conjunto de dados incorporou biomassas do sul do Brasil, juntamente com aquelas encontradas na literatura com base na revisão sistemática. As amostras foram divididas em um conjunto de treino e teste aleatoriamente. Esse procedimento visa encontrar a energia de ativação e o fator pré-exponencial de maneira generalizada, abarcando diversas fontes de biomassa.

No segundo teste, o conjunto de treinamento consistiu em biomassas encontradas na literatura com base na revisão sistemática, enquanto o conjunto de teste é composto exclusivamente por biomassas do sul do Brasil. Essa abordagem buscou avaliar a capacidade da rede neural em prever com precisão os parâmetros cinéticos em um contexto mais regional e específico, destacando a aplicabilidade do modelo para as condições específicas da região sul do Brasil.

5.1 Prevendo parâmetros cinéticos de um conjunto amplo de biomassas

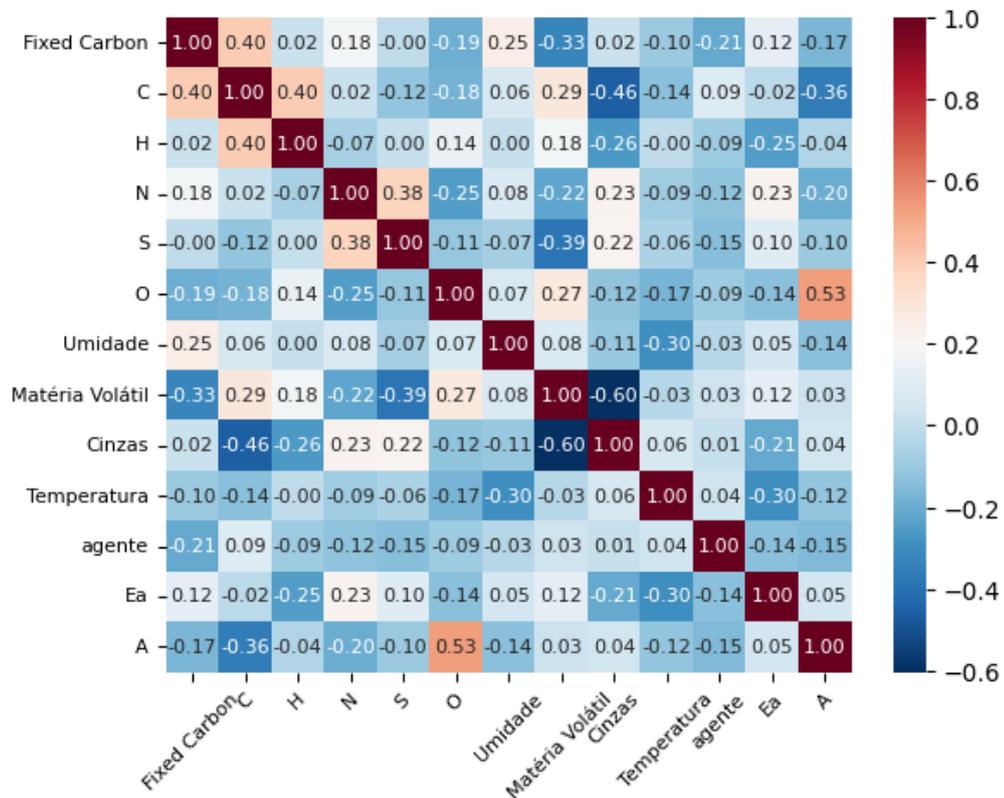
Na condução deste teste, foi empregado um conjunto de dados composto por 40 registros de biomassas provenientes da literatura, que foram agregados a 36 dados específicos de biomassas do Sul do Brasil. Durante a fase de pré-processamento, foi obtida uma quantidade de valores nulos por entrada e saída da rede em porcentagem, conforme ilustrado na Figura 14. Vale ressaltar a presença significativa de valores nulos para o fator pré-exponencial.

Figura 14 – Dados faltantes em porcentagem

Fixed Carbon	2.631579
C	1.315789
H	1.315789
N	3.947368
S	7.894737
O	1.315789
Umidade	14.473684
Matéria Volátil	2.631579
Cinzas	2.631579
Temperatura	7.894737
agente	0.000000
Ea	7.894737
A	35.526316

Fonte: Autoria própria (2023)

A matriz de correlação de Pearson foi calculada, oferecendo insights sobre as relações entre as variáveis de entrada e saída da rede neural, como pode ser observado na Figura 15.

Figura 15 – Matriz de correlação dos dados

Fonte: Autoria própria (2023)

Observando a Figura 15 percebe-se uma significativa correlação positiva entre o teor de oxigênio e o fator pré-exponencial, destacando também relações positivas robustas entre carbono e hidrogênio, assim como entre carbono e carbono fixo. Adicionalmente, evidenciou-se uma correlação negativa expressiva entre matéria volátil e cinzas. Essas associações, já constatadas por Vassilev *et al.* (2010), à exceção do fator pré-exponencial, uma vez que em sua pesquisa não foram considerados os parâmetros cinéticos, levam à conclusão de que a presença, abundância e distribuição dos modos de ocorrência dos elementos desempenham um papel crucial na caracterização da composição da biomassa.

As principais variáveis que afetam a energia de ativação são, a temperatura e os teores de, hidrogênio e nitrogênio. Já para o fator pré-exponencial, são os teores de oxigênio, carbono e nitrogênio.

Posteriormente, foram realizados dois testes distintos para determinar o modelo mais eficiente:

- 1) Utilização de uma única RNA para prever ambos os parâmetros cinéticos;
- 2) Utilização de duas RNAs separadas, cada uma responsável por prever um dos parâmetros.

Juntamente com esse teste, foi conduzida uma análise para identificar a porcentagem ideal de treino e teste, antes de iniciar a busca por melhores pesos. Os resultados indicaram que as redes neurais separadas proporcionaram um desempenho superior, com R^2 e RMSE mais elevados.

No Quadro 6 são apresentados os valores de RMSE e R^2 em função da porcentagem de treino e teste, e da variável de saída da rede.

Quadro 6 – Teste de modelos e porcentagens de treinamento e teste

	80% e 20%	75% e 25%	70% e 30%
	R^2 e RMSE	R^2 e RMSE	R^2 e RMSE
Prevendo EA e A	0,390 e 0,693	0,402 e 0,663	0,369 e 0,693
Prevendo EA	0,807 e 0,386	0,678 e 0,493	0,472 e 0,621
Prevendo A	0,811 e 0,382	0,879 e 0,293	0,758 e 0,419

Fonte: Autoria própria (2023)

A rede com duas saídas, prevendo a energia de ativação e o fator pré-exponencial, apresentou um desempenho inferior em comparação às redes separadas: isso ocorre pela complexidade dos parâmetros cinéticos. Pela matriz de correlação, é possível evidenciar que os dois parâmetros não apresentam relações lineares, tendo interações complexas entre si e entre as entradas; portanto, uma rede dedicada a cada saída permite uma modelagem mais específica para cada propriedade, capturando melhor suas nuances.

A RNA destinada a prever a energia de ativação obteve o melhor desempenho quando configurada com 80% do conjunto de dados para treinamento e 20% para teste. Por outro lado, a RNA voltada para prever o fator pré-exponencial alcançou o melhor resultado com uma divisão de 75% para treinamento e 25% para teste.

Diante da constatação de que o modelo para prever a energia de ativação e o fator pré-exponencial separadamente apresentou os melhores resultados, realizamos uma busca por melhores pesos, executando o modelo dez mil vezes. Essa abordagem permite explorar uma variedade de configurações de pesos iniciais, uma vez que cada execução da RNA se inicializa com pesos aleatórios.

Selecionados os pesos da rodada com o desempenho mais promissor, foi identificado o seed correspondente — um número usado para inicializar o gerador de números aleatórios. Esse processo garante a reprodutibilidade dos resultados, permitindo que outros reproduzam os mesmos resultados ao usar o mesmo seed.

O processo, desde o pré-processamento dos dados até a obtenção dos resultados da RNA, demandou um tempo médio de aproximadamente 10 horas.

Nas Figuras 16 e 17, é ilustrada a configuração da RNA com o melhor resultado encontrado após a busca por pesos.

Figura 16 – Configuração RNA para previsão da energia de ativação (E_a)

Métrica	Valor
Valor de entrada	11
Camadas ocultas	[6, 2]
Taxa de aprendizado	0.1
Número de épocas	250
Tamanho de lote	32
Função de ativação	Gaussiana
Seed	30229
R2	0.857194
RMSE	0.358915

Fonte: Autoria própria (2023)

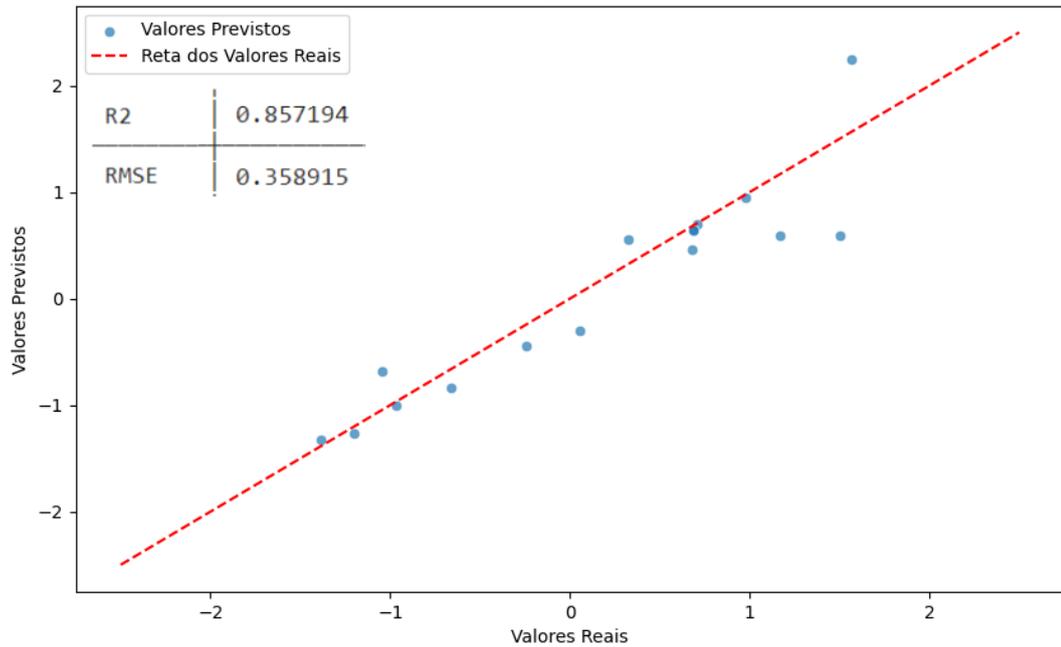
Figura 17 – Configuração RNA para o fator pré-exponencial (A)

Métrica	Valor
Valor de entrada	11
Camadas ocultas	[8, 6]
Taxa de aprendizado	0.1
Número de épocas	200
Tamanho de lote	16
Função de ativação	Gaussiana
Seed	911
R2	0.931336
RMSE	0.235223

Fonte: Autoria própria (2023)

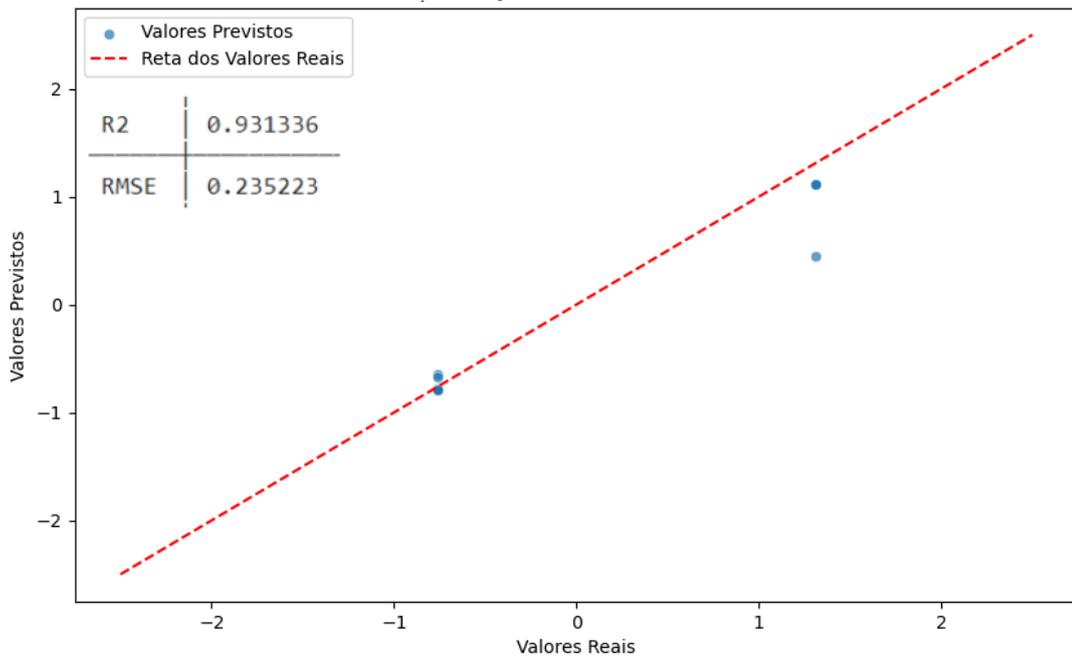
Por fim, foi gerado o gráfico de dispersão dos valores reais em comparação com os valores previstos pelas redes neurais.

Figura 18 – Gráfico de dispersão dos valores reais versus previstos da RNA de energia de ativação



Fonte: Autoria própria (2023)

Figura 19 – Gráfico de dispersão dos valores reais versus previstos da RNA do fator pré-exponencial



Fonte: Autoria própria (2023)

Os resultados foram analisados com base nos valores de R^2 e RMSE, além da obtenção do gráfico de dispersão. Para a RNA responsável pela previsão da energia de ativação, os resultados foram promissores, registrando um R^2 de 0,85 e um RMSE de 0,35. O gráfico de dispersão (Figura 18) revelou uma disposição coerente dos pontos ao longo da curva, indicando um ajuste adequado.

No entanto, ao examinar a RNA dedicada à previsão do fator pré-exponencial, embora o R^2 tenha atingido 0,91 e o RMSE tenha sido baixo (0,23), observou-se uma sobreposição entre muitos pontos no gráfico. Esse fenômeno pode ser atribuído ao elevado número de valores nulos para o fator pré-exponencial no conjunto de dados, aproximadamente 35,5%.

Os resultados obtidos para o R^2 podem ser equiparados aos encontrados no estudo de Ozonoh *et al* (2020), os quais variaram entre 0,75 e 0,98. Apesar da diferença na saída da RNA, que no trabalho em comparação é a eficiência do sistema de gaseificação, podemos concluir que obter resultados dentro dessa faixa sugere um desempenho satisfatório da rede neural.

5.2 Prevendo os parâmetros cinéticos das biomassas do Sul do Brasil

Na execução deste teste, a base de treinamento foi constituída por 40 registros de diversas biomassas encontradas na literatura, combinados com 25 registros de biomassas do sul do Brasil. A base de teste consistiu em 11 registros de biomassas do sul do Brasil que não foram utilizados durante o treinamento da rede.

A matriz de correlação de Pearson não foi regerada, pois engloba os mesmos dados da seção anterior. A única diferença reside na divisão entre treinamento e teste.

Foram realizados dois testes, seguindo a mesma abordagem anterior:

- 1) Utilização de uma única RNA para prever ambos os parâmetros cinéticos;
- 2) Utilização de duas RNAs separadas, cada uma responsável por prever um dos parâmetros.

Neste teste, não foi necessário alterar a porcentagem de treinamento e teste (Quadro 4), pois elas foram estabelecidas no início de forma não aleatória, possibilitando, assim, a avaliação da capacidade da rede em prever os parâmetros cinéticos dessas 11 biomassas do Sul do Brasil em específico. Após realizar a busca por pesos, executando cem mil rodadas da RNA para encontrar a melhor inicialização de pesos e alcançar o maior R^2 , foram obtidas as seguintes configurações para as

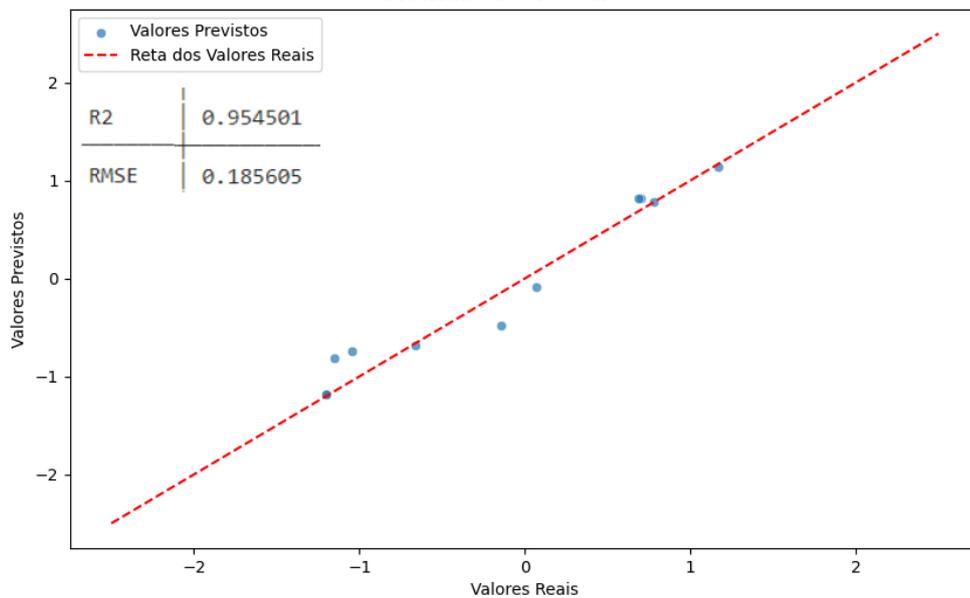
RNAs, juntamente com seus gráficos de dispersão. Nas Figuras 20 e 21 temos os resultados para a RNA prevendo a energia de ativação.

Figura 20 – Configuração RNA para a energia de ativação para prever biomassas do Sul

Métrica	Valor
Valor de entrada	11
Camadas ocultas	[10, 6]
Taxa de aprendizado	0.01
Número de épocas	300
Tamanho de lote	16
Função de ativação	Gaussiana
Seed	3482
R2	0.954501
RMSE	0.185605

Fonte: Autoria própria (2023)

Figura 21 – Gráfico de dispersão dos valores reais versus previstos da RNA para previsão de biomassas do Sul



Fonte: Autoria própria (2023)

O processo, desde o pré-processamento dos dados até a obtenção dos resultados da RNA, demandou um tempo médio de aproximadamente 10 horas.

A RNA destinada à previsão da energia de ativação para biomassas do Sul do Brasil, forneceu um resultado, com R^2 de 0,95 e RMSE de 0,18. Esses indicadores não apenas refletem uma performance adequada da RNA, mas também evidenciam a precisão do modelo em capturar as características específicas das biomassas dessa região, mesmo considerando que a maior parte do dataset seja composta por biomassas diversas. O valor de R^2 , está dentro da faixa encontrada por Ozonoh *et al* (2020) que varia entre 0,75 e 0,98.

Ao compararmos esse desempenho com os resultados da previsão da E_a para biomassas diversas, percebemos um aperfeiçoamento. O aumento do R^2 e a diminuição do RMSE sugerem que o modelo foi refinado de maneira a proporcionar previsões mais acuradas para as biomassas do Sul do Brasil. Tanto os resultados das métricas quantitativas quanto o Gráfico de dispersão (Figura 21) demonstra a precisão do modelo na previsão da E_a para as biomassas brasileiras.

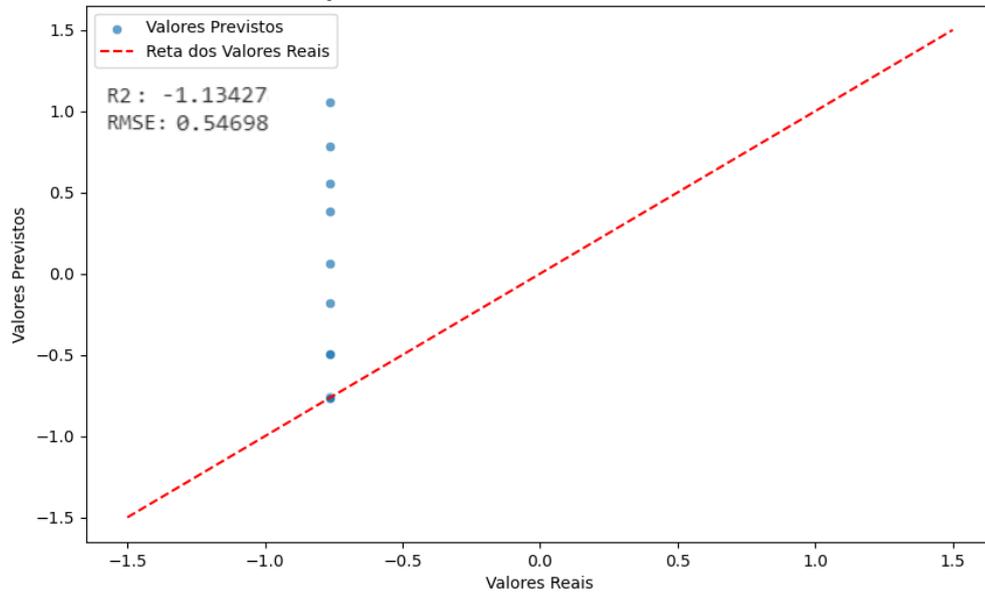
Nas Figuras 22 e 23 temos os resultados para a RNA prevendo o fator pré-exponencial para biomassas do Sul do Brasil.

Figura 22 – Configuração RNA para o fator pré-exponencial para prever biomassas do Sul

Métrica	Valor
input_size	11
hidden_sizes	[8, 6]
learning_rate	0.01
num_epochs	200
batch_size	32
activation	nn.Tanh()
R2 Score	-1.13427
RMSE	0.54698

Fonte: Autoria própria (2023)

Figura 23 – Gráfico de dispersão dos valores reais versus previstos da RNA do fator pré exponencial de biomassa do Sul



Fonte: Autoria própria (2023)

A RNA para previsão do fator pré-exponencial e a RNA para previsão conjunta da energia de ativação e fator pré-exponencial não apresentaram resultados satisfatórios, sendo seus R^2 negativos. De acordo com Gokulprasath (2023), a baixa R^2 negativa sugere que a abordagem proposta pode não se ajustar bem aos dados em termos de explicar a variância, indicando uma captura inadequada das relações subjacentes. Além disso, Chicco; Warrens; Jurman (2021) destacaram em seu trabalho que todos os valores negativos para R^2 indicam um ajuste ainda pior do que a linha média.

No gráfico de previsão do fator pré-exponencial (Figura 23), foi observado que a disposição dos dados está muito parecida com o ilustrado pela Figura 19, com os valores previstos um seguido do outro verticalmente.

A presença de valores ausentes em 35,53% das instâncias do fator pré-exponencial exerce uma influência significativa nas redes neurais propostas, impactando tanto a previsão global quanto a específica para as biomassas do Sul do Brasil.

6 CONCLUSÃO

Em síntese, este estudo focou na determinação dos parâmetros cinéticos da gaseificação de biomassa por meio de redes neurais artificiais.

No primeiro teste, que englobou dados de biomassas da região sul do Brasil e da literatura, os modelos de RNAs obtiveram um R^2 de 0,8571 e RMSE de 0,3589 para a previsão da energia de ativação, e um R^2 de 0,9313 e RMSE de 0,23522 para o fator pré-exponencial. Vale ressaltar que a abordagem de utilizar redes neurais distintas para cada parâmetro cinético superou a opção por um modelo único.

No segundo teste, destinado exclusivamente na predição dos parâmetros das biomassas do sul do Brasil, a previsão do fator pré-exponencial enfrentou desafios evidenciados pelo R^2 negativo. Essa limitação está diretamente relacionada à presença significativa de valores ausentes (35,53%) no conjunto de dados, comprometendo a capacidade da RNA em capturar as relações subjacentes. Esta constatação destaca a necessidade de diminuir os valores nulos nos dados do fator pré-exponencial.

Apesar das dificuldades no segundo teste, o modelo de RNA para prever a energia de ativação, das biomassas do sul do Brasil, alcançaram um R^2 de 0,9545 e RMSE de 0.1856.

Em relação às conclusões sobre o uso da técnica em comparação aos modelos convencionais, é importante considerar que a abordagem com RNAs oferece vantagens significativas. Enquanto os modelos convencionais envolvem análises laboratoriais específicas para cada biomassa, demandando tempo e custos. As RNAs proporcionam uma alternativa mais eficiente, uma vez treinada, pode realizar previsões para diferentes biomassas sem a necessidade de análises laboratoriais adicionais, representando uma economia de recursos e de tempo.

Portanto, a utilização de RNAs destaca-se como uma estratégia eficaz e economicamente viável para a previsão de parâmetros cinéticos na gaseificação de biomassa, especialmente diante da diversidade e singularidade de cada biomassa.

Considerando os resultados obtidos e o escopo deste trabalho, algumas sugestões para pesquisas futuras são propostas. Em primeiro lugar, há a recomendação de ampliar a diversidade do conjunto de dados, incorporando uma variedade mais abrangente de biomassas específicas da região sul do Brasil e de outras regiões, com o foco em ter o mínimo de valores nulos e testar diferentes

abordagens de retirada dos valores nulos. Essa expansão do conjunto de dados poderá proporcionar uma compreensão mais representativa das características da biomassa na gaseificação.

Outra sugestão envolve a realização de comparações sistemáticas entre a abordagem de redes neurais artificiais utilizada neste estudo e outros algoritmos de aprendizado de máquina.

REFERÊNCIAS

- ABDOLRASOL, M. G. M. et al. **Artificial neural networks based optimization techniques**: A review. *Electronics (Switzerland)*, v. 10, n. 21, 2021.
- ALVES, J. L. F., SILVA, J. C. G., PACIONI, T. R., SOARES, D., & JOSÉ, H. J. **Cinética da gaseificação da torta da mamona com CO₂**. Em *Anais do I Congresso Nacional de Engenharia de Petróleo, Gás Natural e Biocombustíveis*. 2016
- AJORLOO, M. et al. **Heavy metals removal/stabilization from municipal solid waste incineration fly ash**: a review and recent trends. *Journal of Material Cycles and Waste Management*, v. 24, n. 5, p. 1693–1717, 2022.
- AKHTAR, A.; KREPL, V.; IVANOVA, T. **A Combined Overview of Combustion, Pyrolysis, and Gasification of Biomass**. *Energy and Fuels*, v. 32, n. 7, p. 7294–7318, 2018.
- ARAUJO, J. V. G. A.; SANTOS, M.; REIS, GOMES, C. F. S. **Desenvolvimento de um código em Python para geração de matrizes de correlação de Pearson com laços a partir de “n” variáveis tomadas duas a duas**. In: SIMPÓSIO DE PESQUISA OPERACIONAL E LOGÍSTICA DA MARINHA, 19., 2019, Rio de Janeiro, RJ. *Anais [...]*. Rio de Janeiro: Centro de Análises de Sistemas Navais, 2019.
- ASCHER, S. et al. **A comprehensive artificial neural network model for gasification process prediction**. *Applied Energy*, v. 320, n. May, p. 119289, 2022.
- BLEIDORN, W., SCHWABA, T., ZHENG, A., HOPWOOD, C., SOSA, SUSANA, ROBERTS, BRENT, BRILEY, DANIEL. **Personality Stability and Change: A Meta-Analysis of Longitudinal Studies**. *Psychological Bulletin*. 148. 10.1037/bul0000365. 2022.
- BRAGA, A. P.; LUDENIR, T. B.; CARVALHO, A. C. P. L. F. **Redes Neurais Artificiais: teorias e aplicações**. Livros Técnicos e Científicos, Rio de Janeiro. 2012.
- BRAND, M.A. **Energia de Biomassa Florestal**. Rio de Janeiro: Editora Interciência, 116 p., 2010
- CARVALHO, Jéssica de Sousa. **Análise imediata e avaliação do poder calorífico superior da biomassa de carnaúba com diferentes aglutinantes para uso em forno industrial**. Trabalho de Conclusão de Curso (graduação) – Universidade Federal do Ceará, Campus de Russas, Curso de Engenharia Mecânica, Russas, 2022
- CASTRO, N.J.; DANTAS, G.A. **Bioenergia no Brasil e na Europa: uma análise comparativa**. In: VII Agrener GD, Fortaleza, 2008.
- CHICCO, D.; WARRENS, M. J.; JURMAN, G. **The coefficient of determination R-squared is more informative than SMAPE, MAE, MAPE, MSE and RMSE in regression analysis evaluation**. *PeerJ Computer Science*, v. 7, p. 1–24, 2021.
- CORTEZ, L. A. B.; LORA, E. E. S.; GÓMEZ, E. O. **Biomassa para energia**. Campinas: Editora Unicamp, 2008.
- COTINO, L. **Big data e inteligencia artificial**. Una aproximación a su tratamiento

jurídico desde los derechos fundamentales. Big data e inteligencia artificial. Una aproximación a su tratamiento jurídico desde los derechos fundamentales, España., n. 27, p. 131–150, 2017.

DA SILVA BINOTI, M. L. M. et al. **Prognose Em Nível De Povoamento De Clones De Eucalipto Empregando Redes Neurais Artificiais.** Cerne, v. 21, n. 1, p. 97–105, 2015.

DANTAS, ET AL. **Bioenergia Versus a Sua Contribuição Nutricional Quando Mantida No Solo.** Revista Brasileira de Produtos Agroindustriais, v. 31, n. 4, p. 1–19, 2016.

DEMIRBAS, A., 2004. **Combustion characteristics of different biomass fuels.** Progress in energy and combustion science, 30(2), pp.219-230.

DERČAN, B. et al. **Possibility of efficient utilization of wood waste as a renewable energy resource in Serbia.** Renewable and Sustainable Energy Reviews, v. 16, n. 3, p. 1516–1527, 2012.

DE LIRA, B. **Recomendação musical para grupos baseada nas preferências individuais.** 2020.

DUARTE, Alexandre Rondelo. 2010. **Uso de Redes Neurais para Previsão do Consumo de Energia em Hotéis.** Trabalho de Conclusão de Curso, Escola Politécnica da USP, São Paulo.

ELBAKYAN, A. “Emancipating knowledge”: Interview with Alexandra Elbakyan, the founder of Sci-Hub. 2020. Disponível em: <https://textumdergi.net/emancipating-knowledge-interview-with-alexandra-elbakyan-the-founder-of-sci-hub/>

EMPRABA. **A cana-de-açúcar.** 2022. Disponível em: <https://www.embrapa.br/visao-de-futuro/trajectoria-do-agro/desempenho-recente-do-agro/cana-de-acucar>. Acesso em: 25. Maio 2023.

EMBRAPA. **O futuro da agricultura brasileira.** 2022. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/cultivos/cana/pos-producao/acucar> Acesso em: 25. Outubro 2023.

EPE. **Balanco energético Nacional,** 2022. Disponível em: <https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-675/topico-638/BEN2022.pdf>. Acesso em: 25 Maio 2023.

FELIX, C. B. et al. **A comprehensive review of thermogravimetric analysis in lignocellulosic and algal biomass gasification.** Chemical Engineering Journal, v. 445, n. May, p. 136730, 2022.

FOLETTTO, E. L. et al. **Applicability of rice husk ash.** Quimica Nova, v. 28, n. 6, p. 1055–1060, 2005.

GENOVESE, A. L.; UDAETA, M. E. M.; GALVÃO, L. C. R. **Aspectos energéticos da biomassa como recurso no Brasil e no mundo.** Encontro de Energia no Meio Rural, p. Atlas de 2 0 1 3. (n.d.). International Energy Age, 2006.

GRACE, J.R.; LECKNER, B.; ZHU, J.; CHENG, Y. **Fluidized Beds**. Em: **Crowe, C.T. Multiphase Flow Handbook**, 1 ed., Cap. 5, Boca Raton, Estados Unidos, CRC Press. 2006.

GOKULPRASATH R. **Extended Linear Regression**: A Kalman Filter Approach for Minimizing Loss via Area Under the Curve. p. 1–7, 2023.

GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep Learning**. MIT Press. 2016

HAYKIN, S. **Redes Neurais**: Princípios e prática, 2.ed. Porto Alegre: Bookman, 2001.

HUMBERTO, J. J.; JONATHAN, A. B. **Escola de combustão** - Capítulo 2: Caracterização de resíduos. Salvador: Rede Nacional de Combustão, 2011.

IBÁ - INDÚSTRIA BRASILEIRA DE ÁRVORES – **Relatório 2019**. Disponível em: <https://iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>. Acesso em: 25 Maio 2023.

IBGE. Lspa – **Levantamento Sistemático da Produção agrícola**. Disponível em: [https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-165/topico-173/PNE%202030%20-%20Gera%C3%A7%C3%A3o%20Termel%C3%A9trica%20\(Biomassa\).pdf](https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-165/topico-173/PNE%202030%20-%20Gera%C3%A7%C3%A3o%20Termel%C3%A9trica%20(Biomassa).pdf). Acesso em: 18 Maio 2023.

JENKINS, B., BAXTER, L.L., MILES Jr, T.R. and MILES, T.R., 1998. **Combustion properties of biomass**. Fuel processing technology, 54(1-3), pp.17-46.

LOO, S. VAN; KOPPEJAN, J. **The Handbook of Biomass Combustion and Cofiring** Edited by Sjaak van Loo and Jaap Koppejan. n. January, p. 426, 2008.

LUIZ, J. et al. **CINÉTICA DA GASEIFICAÇÃO DA TORTA DA MAMONA COM CO₂**. n. 83, 2016.

MALEKIAN, ARASH and NASTARAN CHITSAZ. **Concepts, procedures, and applications of artificial neural network models in streamflow forecasting**. Advances in Streamflow Forecasting (2021): n. pag.

MIRANDA, I. C. DE. **Estudo Dos Parâmetros Cinéticos De Decomposição Térmica De Resíduos Lignocelulósicos E Caracterização Por Ta, Ftir E Edxrf**. p. 336, 2013.

MISHRA, S.; UPADHYAY, R. K. **Review on biomass gasification: Gasifiers, gasifying mediums, and operational parameters**. Materials Science for Energy Technologies, v. 4, p. 329–340, 2021.

MOHAMED, U. **Biomass Chemical Looping Gasification for Power Generation**. n. March, p. 253, 2021.

MORAES, S. et al. **Cenário brasileiro da geração e uso de biomassa adensada**. Revista Ipt Tecnologia E Inovação, v. 1, n. 4, p. 58–73, 2017.

NASCIMENTO, M. et al. **Avaliação dos Dados Monitorados de Qualidade da Água**

usando a detecção de Outliers nas bacias Experimentais e Representativa do Rio Piabanha – Região Serrana do Estado do Rio de Janeiro – RJ . n. 21, p. 1–10, 2021.

NEMER, L. C. **Modelagem do processo de gaseificação de biomassa empregando redes neuronais**. TCC (Graduação)-Curso de Engenharia Química ..., 2010.

NUNES, D., et al. **Inteligencia Artificial e Direito Penal**. Editora Juspodivm, 2022.

OLIVEIRA, A. R. DE; BRAGA, M. B.; SANTOS, B. L. S. **Produção De Biomassa De Cana-De-Açúcar No Vale Do São Francisco**. Energia Na Agricultura, v. 29, n. 1, p. 27, 2014.

OLIVEIRA, L. DE; RUSTICK, A. **Estimativa de vazão de um sistema de bombeamento fotovoltaico usando redes neurais artificiais**. p. 62–72, [s.d.].

OTCHERE, D. A. et al. **Application of supervised machine learning paradigms in the prediction of petroleum reservoir properties: Comparative analysis of ANN and SVM models**. Journal of Petroleum Science and Engineering, v. 200, n. August 2020, p. 108182, 2021.

OZONOH, M. et al. **Performance evaluation of gasification system efficiency using artificial neural network**. Renewable Energy, v. 145, p. 2253–2270, 2020.

PACIONI, T. R. **gaseificação de biochars de bagaço de maçã e de borra de café com co₂: estudo cinético**. UNIVERSIDADE FEDERAL DE SANTA CATARINA CENTRO TECNOLÓGICO PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA, p. 1–109, 2006.

RAJISHA, K. R. et al. **Thermomechanical and spectroscopic characterization of natural fibre composites**. Interface Engineering of Natural Fibre Composites for Maximum Performance, p. 241–274, 2011.

RASHID, T.; KECHADI, M. T. **A Novel Recurrent Neural Network Model: A Case Study in Energy Load Forecasting**. n. August, 2006.

RIBEIRO, A. M.; ARAUJO JUNIOR, F. DE P. S. **Um Estudo Comparativo Entre Cinco Métodos de Otimização Aplicados Em Uma RNC Voltada ao Diagnóstico do Glaucoma**. Revista de Sistemas e Computação, v. 10, p. 122–130, 2020.

ROUSSEEUW, Peter J.; HUBERT, Mia. **Anomaly detection by robust statistics**. WIREs Data Mining and Knowledge Discovery. Lovaina, Belgium, p. 3-4, nov. 2017.

SANTOS, A. M. DOS et al. **Using Artificial Neural Networks and Logistic Regression in the Prediction of Hepatitis A** [in Portuguese]. Rev Bras Epidemiol, v. 8, n. 2, p. 117–126, 2005.

SÁNCHEZ, C. G. **Tecnologia da gaseificação de biomassa**. Editora átomo, campinhas. 2010.

SCHMIDHUBER, J. **Deep learning in neural networks: An overview**. Neural Networks 2015; 61: 85-11

SECRETARIA DE PLANEJAMENTO E DESENVOLVIMENTO ENERGETICO. **Plano Nacional de Energia 2030**. Disponível em: [https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-165/topico-173/PNE%202030%20-%20Gera%C3%A7%C3%A3o%20Termel%C3%A9trica%20\(Biomassa\).pdf](https://www.epe.gov.br/sites-pt/publicacoes-dados-abertos/publicacoes/PublicacoesArquivos/publicacao-165/topico-173/PNE%202030%20-%20Gera%C3%A7%C3%A3o%20Termel%C3%A9trica%20(Biomassa).pdf). Acesso em: 25. Maio 2023.

SHARKAWY, A.-N. **Principle of Neural Network and Its Main Types**: Review. Journal of Advances in Applied & Computational Mathematics, v. 7, p. 8–19, 2020.

SHARMA, K.; KAISARE, N.; GOYAL, H. **A recurrent neural network model for biomass gasification chemistry**. React. Chem. Eng., 2022, 7.570. DOI: 10.1039/d1re00409c.

SILVA, E. et al. **Gaseificação e pirólise para conversão da biomassa em eletricidade e biocombustíveis**. Biocombustíveis - Volume 1, p. 1200, 2012.

SILVA, V. F. **PROCESSOS TERMOQUÍMICOS DE CONVERSÃO DE BIOMASSA**. MSc dissertation, Instituto Politécnico de Bragança, Bragança, 2021.

SILVEIRA, B. I. **Cinética Química das Reações Homogêneas**. Editora Blucher. 2015.

SUNPHORKA, S.; CHALERMSINSUWAN, B.; PIUMSOMBOON, P. **Artificial neural network model for the prediction of kinetic parameters of biomass pyrolysis from its constituents**. Fuel, v. 193, p. 142–158, 2017.

VASSILEV, S. V. et al. **An overview of the chemical composition of biomass**. Fuel, v. 89, n. 5, p. 913–933, 2010.

VERISIMO, G. **Estudo computacional da gaseificação de bagaço de cana-de-açúcar em um reator de leito fluidizado**. Applied Microbiology and Biotechnology, v. 85, n. 1, p. 2071–2079, 2014.

VIEIRA, A. C. **Caracterização da biomassa proveniente de resíduos agrícolas para geração de energia**. Dissertação (Mestrado) – Universidade Estadual do Oeste do Paraná, UNIOESTE, 2012.

VINHA, L. G. DO A.; LAROS, J. A. **Dados ausentes em avaliações educacionais: comparação de métodos de tratamento**. Estudos em Avaliação Educacional, n. x, p. 1, 2018.

WANG, Y.; KINOSHITA, C. M. **Kinetic model of biomass gasification**. Solar Energy, v. 51, n. 1, p. 19–25, 1993.

WALAWENDER, W. E, Hoveland, D. A. & Fan, L. T. **Steam gasification of pure cellulose**. 1 Uniform temperature profile, I & EC Process Des. & Dev. 1985.

WIRTZ, B. W et al. **Artificial Intelligence and the Public Sector**—Applications and Challenges International Journal of Public Administration, v. 42, n. 7, p. 596–615, 2019.

YANG, H.; CHEN, H. 11 - **Biomass gasification for synthetic liquid fuel production**. [s.l.] © 2015 Woodhead Publishing Limited. All rights reserved., 2015.

YUCEL, O, AYDIN, ES, SADIKOGLU, H. **Comparison of the different artificial neural networks in prediction of biomass gasification products.** Int J Energy Res. 2019; 43: 5992–6003. <https://doi.org/10.1002/er.4682>

APÊNDICE A - Base de dados

Titulo	Biomassa	Fixed Carbon	C	H	N	S	O	Umidade	Matéria Volátil	Cinzas	Temperatura	agente	Ea	A
Thermogravimetric and kinetic analysis of high-temperature thermal conversion of pine wood sawdust under CO ₂ /Ar et al	Pine Wood	15,17	44,54	5,36	0,41	0,06	47,78	4,52	78,46	1,85	1673,15	CO	180,91	
Effect of calcium ferrites on carbon dioxide gasification reactivity and kinetics of pine wood derived char	Pine Wood	15,17	44,54	5,36	0,41	0,06	47,78	4,52	78,46	1,85	1673,15	CO	188,52	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	torrefied pine sawdust PINT	21	54,5	5,7	0,4	0,02	38,98	6,4	78,6	0,4	1273,15	HO	179,4	68,4
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	torrefied pine sawdust PINT	21	54,5	5,7	0,4	0,02	38,98	6,4	78,6	0,4	1273,15	HO	180,4	120000
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	pine kernel shell PKS	19,8	52,3	6,2	0,6	0,05	39,05	9,4	78,4	1,8	1273,15	HO	72,6	0,26
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	pine kernel shell PKS	19,8	52,3	6,2	0,6	0,05	39,05	9,4	78,4	1,8	1273,15	HO	72,6	0,25
Numerical Investigation on the Effects of Gas Induction Velocity on the Performance of a Fluidized Bed Reactor	Pine Wood	14,77	46,29	6,48	0,5	0,5	46,08	11,89	71,78	1,56	1093	HO		
Gasification of lignocellulosic biomass char obtained from pyrolysis: Kinetic and evolved gas analyses	Pine Bark	31,3	52,71	5,52	0,01	0,08	41,7	4,4	61,6	2,7	1173,15	HO		
Kinetics of biomass and waste during pyrolysis and steam gasification	Yellow Pine Woodchips	8,5	52,6	06,01	0	0	40,1		90,4	1,1	1173,15	HO	69,6	3,2
Kinetics of pyrolysis, combustion and gasification of three biomass fuels	Pine seed shells	19,4	48,5	6,1	0,2	0,1	44,3	10,3	69,2	1,1	1173,15	CO	51	2100000
Kinetics of pyrolysis, combustion and gasification of three biomass fuels	Wood chips	13,3	47,3	6,1	0,2	0,1	46	34,9	51,6	0,2	1173,15	CO	62	1100000000
Cinética da co-gaseificação de lodo de esgoto sanitário e serragem de pinus com vapor de água em um reator termogravimétrico	Serragem de pinus (bruto)	14,04	47,18	07,06	0	0	45,42		85,61	0,33	1173,15	HO	144	
Cinética da gaseificação do bagaço de laranja e serragem de madeira com CO ₂	Serragem de madeira	16,03	53,98	5,98	0,74	0,06	38,96	18,23	83,97	0,89	1073	CO	226,1	0,0000347
Cinética da gaseificação do bagaço de laranja e serragem de madeira com CO ₂	Serragem de madeira	16,03	53,98	5,98	0,74	0,06	38,96	18,23	83,97	0,89	1073	CO	180,7	0,0000138
Kinetic analysis of CO ₂ gasification of biochar and anthracite based on integral isoconversional nonlinear method	Feedstock sawdust	16,83	48,89	6,75	0,44	0,08	41,39	8,67	80,72	2,45	1553	CO	143,8	367000
Kinetics of co-gasification of rice husk biomass and high sulphur petroleum coke with oxygen as gasifying medium via TGA	rice husk	4,38	46,83	3,58	2,43	0,05	47,11	7,16	73,14	15,31	1173,15	O	67,61	
Evaluating performance of pyrolysis and gasification processes of agriculture residues-derived hydrochar: Effect of hydrothermal carbonization	rice husk	62,8	47,9	6,8	0,8	0,3	44,3	3,6	62,8	18,4	1373,15	CO		
Promotion and inhibition effect of K in rice husk during chemical looping gasification	rice husk	13,71	40,78	5,58	0,82	0,41	52,41	8,43	65,53	12,33	1073,15	O	359,042	
As for carbon dioxide gasification of rice husk char	Rice husk	15,22	37,35	4,4		0,2	34,05	6,86	60,92	17	1173,15	CO	229,465	14280000
kinetic effects analyses of petroleum coke and biomass	Rice husk	16,89	46,18	06,08	2,62	0,1	45,02	05,08	63,05	14,98	1173,15		74,8	
Thermal gasification of rice husk and chicken manure	Rice husk	18,46	48,25	6,58	0,52	0,01	44,63	6,2	70,68	10,86	873			
Gasification of biomass char with a red mud oxygen carrier for	Rice husk		37,66	4,81	0,42	0	31,97				1223	CO	318	
Sugarcane bagasse gasification in a downdraft fixed-bed gasifier: Optimization of operation conditions	sugar	16,39	44,1	5,7	0,2	2,3	47,7	7,23	76,94	4,41	1373,15		75,35	
Assessment of sugarcane bagasse gasification in supercritical water for hydrogen production	sugar	14,03	47,09	6,16	0,52	01,08	42,5	4,46	83,32	2,65	1023,15	HO	117,88	5
Energy recovery analysis from sugar cane bagasse pyrolysis and gasification using thermogravimetry, mass spectrometry and kinetic models	sugar	10,6	44,26	5,76			40,88	8,3	72	9,1	1223,15	HO	135,52	233000
Kinetic study and synergistic interactions on catalytic CO ₂ gasification of Sudanese lower sulphur petroleum coke and sugar cane bagasse	sugar	12,23	46,95	06,06	0,13	0,08	42,44		83,01	5	1223,15	CO	168,52	57,9
Kinetics of steam-char reaction of olive residues	olive residues	23,8	52,1	6,4	1,2	0,1	36,1	2	70,2	4	1023,15		161	

https://www.nrel.gov/docs/legosti/odd/239-2.pdf	Pine sawdust	16,8	51	6	0,1		42,8		83,1	0,1	1273,15	CO	229		
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	Almond shell	19,6	49,4	5,9	0,3	0,05	42,85	6,5	78,9	1,5	1273,15	CO	85,9	196	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	Coffe dregs	21,2	48	5,7	3,7	0,27	33,73	7,2	70,2	8,6	1273,15	CO	57,2	254	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	coffee husk	16,6	49,6	6,1	3	0,22	36,88	8,4	79,2	4,2	1273,15	CO	168,2	1520000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	chestnut sawdust	18,3	50,2	5,6	0,3	0,01	43,39	8,4	81,2	0,5	1273,15	CO	157,5	307000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	cocoa shell	21,7	48	5,9	2,7	0,21	35,29	6,7	70,4	7,9	1273,15	CO	170,9	9420000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	grape pomace	19,7	45,5	5,1	1,8	0,17	34,73	11,6	67,6	12,7	1273,15	CO	127	36200	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	miscanthus	13,2	48	5,8	0,4	0,11	36,49	5,6	77,6	9,2	1273,15	CO	64,5	9,48	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	olive stones	17,9	51,2	6	51,2	0,03	41,87	4,3	81,5	0,6	1273,15	CO	196,1	22900000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	pine cone leaf	22,4	52,9	6,1	52,9	0,03	39,47	10,1	76,5	1,1	1273,15	CO	188,8	11900000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	torrefied pine sawdust	21	54,5	5,7	54,5	0,02	38,98	6,4	78,6	0,4	1273,15	CO	180,6	7860000	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	pine kernel shell	19,8	52,3	6,2	52,3	0,05	39,05	9,4	78,4	1,8	1273,15	CO	72,7	24,2	
Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity	switchgrass	15,7	47,8	5,7	47,8	0,1	41	12,4	79,7	4,6	1273,15	CO	171,2	2550000	
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Barley straw (BS)	14,7	40,87	5,78	0,55	0	52,8	8,95	78,15	7,15	1273,15	CO	84,69		
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Miscanthus (MS)	16,33	42,67	5,86	0,44	0	51,04	6,91	78,29	5,38	1273,15	CO	92,11		
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Waste wood (WW)	14,06	45,78	06,05	0,34	0	47,84	5,8	84,48	1,46	1273,15	CO	86,72		
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Wheat straw (WS)	18,22	41,32	5,69	1,18	0	51,81	6,41	72,28	9,5	1273,15	CO	98,68		
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Willow SRC (SRC)	13,24	45,18	5,99	0,32	0	48,51	5,97	85	1,77	1273,15	CO	76,95		
Thermal and kinetic analysis of diverse biomass fuels under different reaction environment: A way forward to renewable energy sources	Wood pellet (WP)	14,28	47,02	6,17	0,07	0	46,75	6,34	84,94	0,79	1273,15	CO	81,67		
Kinetic analysis and thermodynamics properties of air/steam gasification of agricultural waste	sawdust	11,06	44,71	1,48	4,2	0,28	49,33	6,85	80,9	1,19	915,66	CO	218,27	4,158E+25	
Kinetic analysis and thermodynamics properties of air/steam gasification of agricultural waste	plum	15,55	48,95	1,38	0,99	0,27	48,41	5,86	77,86	0,73	563,66	CO	143,7	3,06E+16	
Kinetic analysis and thermodynamics properties of air/steam gasification of agricultural waste	olive pits	15,87	52,79	2,57	1,39	0,5	42,75	4,55	77,25	2,33	653,66	CO	87,89	2,226E+11	
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	10-year-old bamboo-willow (BW1)	17,25	48,91	5,97	0,91	0,05	42,38		81,03	1,72		CO	154,18		
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	willow (W1)	16,44	48,74	5,42	0,5	0,06	40,94		79,23	4,33		CO	159,3		
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	pinus sylvestris (PS)	15,11	43,3	5,56	0,14	0,05	50,28		84,27	0,62		CO	174		
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	abies fabri	17,31	49,38	5,73	0,17	0,06	43,75		81,74	0,95		CO	187,66		
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	picea jezoensis (PJ)	15,42	48,7	5,64	0,2	0,05	44,57		83,69	0,89		CO	179,44		
Comparative study on pyrolysis and gasification within CO2 atmosphere of typical forestry biomass in Northeast Asia: Thermal behavior and	picea koraiensis (PK)	14,19	38,77	5,49	0,17	0,06	55,01		85,31	0,5		CO	164,92		

pyrolysis, combustion and gasification of three b	Olive husk	26,2	51,8	5,5	1,2	0,1	36,3	13,1	56,3	4,4	1173,15	CO	48	8000000	
"GASEIFICAÇÃO DE BIOCHARS DE BAGAÇO DE MAÇÃ E DE BORRA DE CAFÉ COM CO ₂ : ESTUDO CINÉTICO"	char de borra de café depois da pirólise	71,12	86,63	2,58	3,38	0,41	7	0,9	17,02	11,86	1128,15	CO	185,8	0,00002007	
"GASEIFICAÇÃO DE BIOCHARS DE BAGAÇO DE MAÇÃ E DE BORRA DE CAFÉ COM CO ₂ : ESTUDO CINÉTICO"	char de bagaço de maçã depois da	78,42	88,11	2,55	2,15	0,21	6,99	1,11	14,24	7,34	1128,15	CO	165,8	0,00000402	
Cinética da gasificação do bagaço de laranja e serragem de madeira com CO ₂	Serragem de madeira	23,17	49,09	5,9	2,27	0	42,74	9,56	76,83	06,09	1073	CO	179,6	0,000126	
DE RESÍDUOS SÓLIDOS DA INDÚSTRIA ALIMENTÍCIA *	Borra de Café	20,71	44,8	5,5	10,8		38,8	11,72	69,25	10,05	873,15	CO	155,18	1,27E-07	
DE RESÍDUOS SÓLIDOS DA INDÚSTRIA ALIMENTÍCIA *	Semente de Goiaba	16,4	47,7	5,9	3,2		43,1	15,2	80,94	2,66	873,15	CO	214,53	936000000	
DE RESÍDUOS SÓLIDOS DA INDÚSTRIA ALIMENTÍCIA *	Bagaço de caju	22,57	48,7	5,8	3,5		41,9	76,05	74,36	03,07	873,15	CO	297,77	2,52E+13	
Agricultural waste-derived biochars from co-hydrothermal gasification of rice husk and chicken manure and their adsorption performance for dimethoate	chicken manure	8,92	26,78	5,98	18,25	0,12	30,4	1,6	40,5	5,58	873	HO			
Kinetics, thermodynamics and synergistic effects analyses of petroleum coke and biomass wastes during H ₂ O co-gasification	Rice Stalk	10,28	40,25	4,58	0,99	0,07	34,15	3,45	69,77	16,5	1373,15	HO	110,43	31,4	
Kinetics, thermodynamics and synergistic effects analyses of petroleum coke and biomass wastes during H ₂ O co-gasification	Saw dust	13,47	49,78	5,85	0,28	0,02	36,99	3,18	79,45	3,9	1373,15	HO	93,98	21,1	
Kinetics, thermodynamics and synergistic effects analyses of petroleum coke and biomass wastes during H ₂ O co-gasification	Cotton Straw	10	46,09	5,6	0,96	0,06	38,22	2,48	80,92	6,6	1373,15	HO	103,26	24,6	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	torrefied pine sawdust PINT	21	54,5	5,7	0,4	0,02	38,98	6,4	78,6	0,4	1273,15	HO	180,6	130000	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	torrefied pine sawdust PINT	21	54,5	5,7	0,4	0,02	38,98	6,4	78,6	0,4	1273,15	HO	179,6	89900	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	pine kernel shell PKS	19,8	52,3	6,2	0,6	0,05	39,05	9,4	78,4	1,8	1273,15	HO	72,7	0,4	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	pine kernel shell PKS	19,8	52,3	6,2	0,6	0,05	39,05	9,4	78,4	1,8	1273,15	HO	72,6	0,3	
"Unconventional biomass fuels for steam gasification: Kinetic analysis and effect of ash composition on reactivity"	Serragem de madeira	16,03	53,98	5,98	0,74	0,06	38,96	18,23	83,97	0,89	1073	CO	206,8	0,000392	
Kinetics, thermodynamics and synergistic effects analyses of petroleum coke and biomass wastes during H ₂ O co-gasification	Rice husk	16,38	40,72	5,19	0,69	0,08	33,86	5,37	64,14	14,11	1373,15	HO	132,39	3,76E+10	
Kinetic analysis of CO ₂ gasification of biochar and anthracite based on integral isoconversional nonlinear method	Rice husk	15,13	42,23	4,41	0,41	0,07	35,22	07,02	67,21	17,66	1553	CO	184,8	10800000	
Kinetic analyses and synergistic effects of CO ₂ co-gasification of low sulphur petroleum coke and biomass wastes	Rice husk	16,38	40,72	5,19	0,69	0,08	33,86	5,37	64,14	14,11	1373,15	CO	81,61	17,4	
Kinetics, thermodynamics and synergistic effects analyses of petroleum coke and biomass wastes during H ₂ O co-gasification	sugar	11,33	46,95	06,06	0,13	0,08	42,44	7,23	76,94	4,41	1373,15	HO	144,58	44,4	
Kinetic analyses and synergistic effects of CO ₂ co-gasification of low sulphur petroleum coke and biomass wastes	sugar	11,33	46,95	06,06	0,13	0,08	42,44	7,23	76,94	4,41	1373,15	CO	75,35	15	