



**UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA**

MARCOS LAPA BRITO

**ANÁLISE DE CENÁRIOS A PARTIR DE INDICADORES ENERGÉTICOS E
AMBIENTAIS PARA AS EMISSÕES BRASILEIRAS DE CO₂**

**Salvador
2024**

MARCOS LAPA BRITO

**ANÁLISE DE CENÁRIOS A PARTIR DE INDICADORES ENERGÉTICOS E
AMBIENTAIS PARA AS EMISSÕES BRASILEIRAS DE CO₂**

Tese apresentada ao Programa de Pós-Graduação em Engenharia Química da Universidade Federal da Bahia, como requisito parcial para a obtenção do grau de Doutor em Engenharia Química.

Orientadores: Dr. George Simonelli e Dr. Luiz
Carlos Lobato dos Santos

Salvador
2024

Ficha catalográfica elaborada pela Biblioteca Bernadete
Sinay Neves, Escola Politécnica - UFBA.

B862 Brito, Marcos Lapa.

Análise de cenário a partir de indicadores energéticos e ambientais
para as emissões brasileiras de CO₂ / Marcos Lapa Brito. – Salvador,
2025.

117 f.: il. color.

Orientador: Prof. Dr. George Simonelli.

Orientador: Prof. Dr. Luiz Carlos Lobato dos Santos.

Tese (doutorado) – Programa de Pós-Graduação em Química -
Universidade Federal da Bahia - Escola Politécnica, 2025.

1. Emissões de CO₂. 2. Rede neural artificial. 3. Recursos energéticos
fósseis e renováveis. 4. Queimadas brasileiras. I. Simonelli, George. II.
Santos, Luiz Carlos Lobato dos. III. Universidade Federal da Bahia. IV.
Título.

CDD: 577.144




UNIVERSIDADE FEDERAL DA BAHIA
ESCOLA POLITÉCNICA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA QUÍMICA




A Comissão examinadora, abaixo assinada, aprova a Tese “**Análise de cenários a partir de indicadores energéticos e ambientais para as emissões brasileiras de CO₂**”, de **Marcos Lapa Brito**, como requisito parcial para obtenção do grau de Doutor em Engenharia Química.

Salvador, 08 de novembro de 2024.


Comissão Examinadora:

Documento assinado digitalmente
 **GEORGE SIMONELLI**
Data: 12/11/2024 06:51:20-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. George Simonelli
Orientador, UFBA


Documento assinado digitalmente
 **LUIZ CARLOS LOBATO DOS SANTOS**
Data: 12/11/2024 14:17:00-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Luiz Carlos Lobato dos Santos
Orientador, UFBA


Documento assinado digitalmente
 **LUIZ MARIO NELSON DE GOIS**
Data: 14/11/2024 10:56:28-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Luiz Mario Nelson de Góis
Examinador Interno, UNIFACS

Prof. Dr. José Mario Ferreira Junior
Examinador Externo, UIOWA

Documento assinado digitalmente
 **JOAO PAULO LOBO DOS SANTOS**
Data: 12/11/2024 14:40:39-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. João Paulo Lobo dos Santos
Examinador Externo, UFS

Documento assinado digitalmente
 **ROMERO FLORENTINO DE CARVALHO**
Data: 13/11/2024 07:39:23-0300
Verifique em <https://validar.iti.gov.br>

Prof. Dr. Romero Florentino de Carvalho
Examinador Externo, UFES

RESUMO

O Brasil é um país em desenvolvimento que emite altas quantidades de CO₂ por ano. Portanto, controlar essas emissões é essencial para alcançar o desenvolvimento sustentável. Nessa tese, testamos seis Redes Neurais Artificiais (4 do tipo retropropagação e 2 do tipo cascata) e dessas, uma do tipo retropropagação foi capaz de relacionar quantitativamente as emissões de CO₂, matriz energética e queimadas nos biomas brasileiros, como a Floresta Amazônica. A literatura, ainda não possui trabalhos que demonstrem quantitativamente o impacto que as alterações na matriz energética brasileira possuem nas emissões de CO₂ no país. Além disso, também não se encontra estudos que utilizam as queimadas nos biomas brasileiros como entrada nos modelos preditivos para as emissões. Nossos resultados mostraram que as emissões brasileiras de CO₂ aumentarão nos próximos anos. No entanto, a substituição parcial de recursos energéticos fósseis por renováveis associados à redução de incêndios nos biomas brasileiros poderia reduzir significativamente essas emissões. Em nosso primeiro cenário em que houve uma substituição parcial de 30% dos recursos fósseis pelos renováveis e uma redução de 70% nas queimadas dos biomas brasileiros, as emissões de CO₂ diminuíram em 13,58% para o ano de 2030. Já no segundo cenário analisado, substituímos os combustíveis fósseis em 90% pelos renováveis, enquanto as queimadas nos biomas brasileiros foram reduzidas em 90%. Nessa situação, observamos uma redução de 28,45% nas emissões brasileiras de CO₂. Assim, o modelo aqui desenvolvido pode ajudar o Brasil a prever e controlar suas emissões de CO₂ a partir de mudanças em seus indicadores energéticos e ambientais para encontrar o equilíbrio entre desenvolvimento e sustentabilidade. Nosso modelo também pode ser usado por outros países em desenvolvimento. Para isso, é necessário que os indicadores sejam adaptados à realidade do país estudado.

Palavras-chave:

Emissões de CO₂, Rede Neural Artificial, Recursos Energéticos Fósseis e Renováveis, Queimadas Brasileiras.

ABSTRACT

Brazil is a developing country that emits high amounts of CO₂ per year. Therefore, controlling these emissions is essential to achieve sustainable development. In this thesis, we tested six Artificial Neural Networks (4 feedback propagation and 2 cascade feedback propagation) and of these, one feedback propagation was able to quantitatively relating CO₂ emissions, energy matrix and burning in Brazilian biomes, such as the Amazon Forest. The literature still does not have studies that quantitatively demonstrate the impact that changes in the Brazilian energy matrix have on CO₂ emissions in the country. In addition, there are also no studies that use fires in Brazilian biomes as input in predictive models for emissions. Our results showed that Brazilian CO₂ emissions will increase in the coming years. However, partial replacement of fossil energy resources with renewables associated with the reduction of fires in Brazilian biomes could significantly reduce these emissions. In our first scenario, in which there was a partial replacement of 30% of fossil resources by renewable ones and a 70% reduction in the burning of Brazilian biomes, CO₂ emissions decreased by 13.58% for the year 2030. In the second scenario analyzed, we replaced fossil fuels by 90% with renewable ones, while burning in Brazilian biomes was reduced by 90%. In this situation, we observed a 28.45% reduction in Brazilian CO₂ emissions. Thus, the model developed here can help Brazil to predict and control its CO₂ emissions from changes in its energetic and environmental indicators to find a balance between development and sustainability. Our model can also be used by other developing countries. For this, it is necessary that the indicators are adapted to the reality of the country studied.

Keywords:

CO₂ emissions, Artificial Neural Network, Fossil and Renewable Energy Resources, Brazilian burning.

LISTA DE FIGURAS

Figura 1: % do PIB investido em P&D pelos países no ano de 2016.....	27
Figura 2: Evolução do consumo energético por cenário econômico.....	30
Figura 3: Projeções da participação das fontes energéticas no consumo final de energia entre 2015 e 2050 para os cenários inferior e superior do crescimento econômico.....	31
Figura 4: Evolução do consumo energético por setor produtivo.....	32
Figura 5. Participação das fontes energéticas no consumo final do setor industrial.....	32
Figura 6. Esquema de um neurônio artificial.....	36
Figura 7. Representação simplificada de uma Rede Neural Artificial de 3 camadas.....	38
Figura 8. Representação de um neurônio artificial linear calculando o preço final de um lanche em uma hamburgueria.....	40
Figura 9. Representação gráfica da saída de um neurônio artificial sigmoidal.....	42
Figura 10. Representação gráfica da saída de um neurônio artificial <i>tahn</i>	43
Figura 11. Representação gráfica da saída de um neurônio artificial <i>ReLU</i>	44
Figura 12. Dígitos manuscritos para serem reconhecidos por uma RNA.....	45
Figura 13. Rede Neural Artificial utilizando o algoritmo de Retro Propagação que permite o fluxo de informações em 2 sentidos através da arquitetura da rede.....	48
Figura 14. Indicadores socioambientais brasileiros normalizados para o período de 1998 a 2018.....	67

Figura 15. Exemplo de uma Rede Neural Artificial do tipo <i>Cascade Feed Forward Back</i> <i>Propagation</i>	68
Figura 16. Exemplo de uma Rede Neural Artificial do tipo <i>Feed Forward Back</i> <i>Propagation</i>	68
Figura 17. Representação gráfica da saída de uma função de ativação sigmoidal.....	69
Figura 18. Tendência dos 9 indicadores brasileiros no período de 2019 – 2030.....	76
Figura 19. Previsões de emissão brasileira de CO ₂ de 2019 a 2030.....	77
Figura 20. Tendência normal das emissões brasileiras de CO ₂ e previsões para os cenários analisados, entre 2019 – 2030. 1º Cenário: Substituição parcial dos recursos fósseis pelos renováveis em 30% e redução das queimadas nos biomas brasileiros em 70%. 2º Cenário: Substituição parcial dos recursos fósseis pelos renováveis em 90% e redução das queimadas nos biomas brasileiros em 90%.....	80

Lista de Tabelas

Tabela 1: Número de camadas ocultas, número de neurônios nas camadas e Erro Médio Quadrático para cada Rede Neural Artificial

Modelada.....

74

Tabela 2: Ranqueamento da influência de cada indicador nas emissões brasileiras de

CO₂.....

75

LISTA DE ABREVIATURAS E SIGLAS

BRICS	Brasil, Rússia, Índica, China e África do Sul
CE	Consumo de Eletricidade
CFFBP	Cascade Feed Forward Back Propagation
CM	Participação de carvão mineral e outros recursos fósseis em FTEP
COP	Conference of the Parties
EPE	Empresa de Pesquisas Energéticas
FAO	Food and Agriculture Organization of United Nation
FFBP	Feed Forward Back Propagation
FR	Participação de fontes de energia renovável no FTEP
FTEP	Fornecimento Total de Energia Primária
GN	Participação de gás natural no FTEP
ICMS	Imposto Sobre Circulação de Mercadorias e Serviços
IEA	Agência Internacional de Energia
INDCs	Intended Nationally Determined Contributions
P	População
P&D	Pesquisa e Desenvolvimento
PE	Políticas Energéticas
PIB	Produto Interno Bruto
PNE 2050	Plano Nacional de Energia
PP	Participação total de petróleo e seus derivados no FTEP
PTF	Produtividade Total dos Fatores
Queimadas	Incêndios na Floresta Amazônica e em outros biomas brasileiros
ReLU	Restricted Linear Unit
RNA	Rede Neural Artificial
UFCCC	United Nations Framework Convention on Climate Change

SUMÁRIO

1. INTRODUÇÃO	11
1.1. OBJETIVO.....	15
2. Revisão Bibliográfica.....	16
2.1. CRESCIMENTO DO CONSUMO ENERGÉTICO.....	16
2.3. Emissões de CO ₂ e o aquecimento global.....	18
2.4. Consequências do aquecimento global	19
2.5. Estratégias e tecnologias para a redução do CO ₂	21
2.6. Energia solar	22
2.7. Energia eólica.....	22
2.8. Combustíveis renováveis	23
2.9. O gás hidrogênio como combustível.....	24
2.10. Metas da Conferência das Partes da Convenção Quadro das Nações Unidas sobre Mudança no Clima	25
2.11. Protocolo de Kyoto: 1997	25
2.12. O Acordo de Paris: 2015	27
2.13. Políticas Energéticas e o Acordo de Paris	28
2.14. O Brasil e o seu Plano Nacional de Energia para 2050	29
2.15. A produtividade brasileira e os seus indicadores	29
2.16. Demanda energética brasileira até 2050	33
2.17. Redes Neurais Artificiais	39
2.17.1. As máquinas inteligentes e suas limitações	39
2.17.2. Redes Neurais Artificiais e o modelo de neurônio artificial	40
2.17.3. Arquiteturas das Redes Neurais Artificiais	42
2.17.4. Limitações dos neurônios artificiais lineares e a introdução da não linearidade nas funções de transformação.....	45
2.17.5. O treinamento das Redes Neurais Artificiais e o algoritmo de Retropropagação (<i>Back Propagation</i>)	45
2.17.6 A utilização das Redes Neurais Artificiais em problemas do setor energético	49
2.17.8 Modelagens para a predição das emissões de CO ₂ no Brasil	55
3 Materiais e Métodos	64
3.1 Atividades Principais	64
3.2. Coleta de dados para as entradas e saídas da RNA	64
3.3. Estrutura da Rede Neural Artificial.....	66
3.4. Treinamento da Rede Neural Artificial	69
4.4. Processo de validação e análise de erros	69
3.5. Análise das simulações de cenários.....	70

4	Resultados e Discussões.....	73
4.1	Seleção das Redes Neurais e previsões das emissões de CO ₂	73
4.2	Análise de Cenários	78
5.	CONCLUSÃO.....	82
6.	Sugestão para trabalhos futuros.....	85
	REFERÊNCIAS.....	86
	APÊNDICE A.....	107
	APÊNDICE B.....	108
	APÊNDICE C.....	110

1. INTRODUÇÃO

Nesta pesquisa, demonstramos quantitativamente como a substituição parcial dos recursos energéticos fósseis por renováveis e a redução das queimadas nos biomas brasileiros, como a Floresta Amazônica, reduzem as emissões brasileiras de dióxido de carbono. Portanto, a política energética brasileira é um elemento crítico para atingir a meta de redução fixada no Acordo de Paris (2015) para as emissões brasileiras de dióxido de carbono.

A literatura ainda não apresenta muitos estudos que relacionam as previsões das emissões brasileiras de CO₂ e os fatores que mais as favorecem. Kone e Buke (2010) fizeram previsões para as emissões de dióxido de carbono nos 25 países mais emissores do mundo. Os autores utilizaram uma série temporal (emissão de CO₂ dependente do ano) entre 1971-2007. A partir dessa base de dados, foram realizadas análises de regressão para cada país para obter uma equação para emissão de dióxido de carbono entre 2008-2010. Em relação ao Brasil, o estudo encontrou uma tendência de aumento das emissões de CO₂, que seriam de aproximadamente 381,65 (Mt) e 478,61 (Mt) nos anos de 2008 e 2010, respectivamente (KONE; BUKE, 2010). Com o passar dos anos, essa tendência foi concretizada, entretanto, o estudo as superestimou, pois as emissões brasileiras de CO₂ em 2008 e 2010 foram respectivamente de 413 (Mt) e 440 (Mt) (*Global Carbon Atlas*). Schulz e Ruppenthal (2018) aplicaram a metodologia *Box & Jenkins* para estudar as séries temporais das emissões brasileiras de dióxido de carbono entre 1960 e 2013. Após analisar as emissões nesse período, os autores concluíram que as séries temporais estudadas não são estacionárias, apresentando uma tendência de crescimento ao longo dos anos. Apesar das previsões baseadas em séries temporais revelarem uma tendência crescente das emissões brasileiras de CO₂, elas não são capazes de mostrar quais fatores brasileiros mais contribuem para essa tendência.

Para reduzir as emissões brasileiras de CO₂ e relacioná-las com seus indicadores mais relevantes, alguns autores utilizaram modelos que não fossem séries temporais. Pao e Tsai (2011) fizeram modelos preditivos para emissões de dióxido de carbono, consumo de energia e crescimento econômico no Brasil. Os autores

utilizaram o *Grey Model* para analisar o comportamento das variáveis entre os anos de 1980 a 2007. Além disso, eles previram essas variáveis entre os anos de 2008 a 2013. A partir dos resultados, os autores encontraram uma relação entre as emissões de dióxido de carbono e o consumo de energia no Brasil. Além disso, verificou-se que ao consumir mais energia no país, há uma maior emissão de CO₂. Assim, os autores sugerem que o governo brasileiro invista no setor de energia para torná-lo mais eficiente, reduzindo assim o desperdício de energia.

Wu et al. (2020) desenvolveram um modelo preditivo para emissões de dióxido de carbono em países do “BRICS” (Brasil, Rússia, Índia, China e África do Sul). Os dados usados foram do período entre 2000 e 2018, e as previsões foram feitas para o período 2019-2025. Os autores usaram o *Grey Model* e constataram, para o Brasil, o aumento de suas emissões de dióxido de carbono ano após ano. Dessa forma, foi possível observar o comportamento das emissões de CO₂ para os países investigados. Entretanto, os autores não incluíram outras variáveis independentes além do tempo para investigar as emissões.

Ahmed, Ahmed e Ismail (2020) usaram a *Gray System Theory* para prever as emissões de dióxido de carbono nos países do “BRICS”. Os indicadores utilizados foram o desenvolvimento econômico, o surgimento de novas tecnologias e o consumo de energia. Para o Brasil, os autores utilizaram o banco de dados para cada variável entre o período de 1990 a 2014. As emissões brasileiras de CO₂ foram previstas para 2015 a 2024. Com base nos resultados, houve um aumento substancial das emissões de dióxido de carbono no Brasil para os próximos anos, tendência justificada pela forte dependência do país em relação aos combustíveis fósseis. Sendo assim, os autores indicaram que o maior uso de energia renovável poderia reduzir as emissões de dióxido de carbono no Brasil, contribuindo para a sustentabilidade do planeta.

Acheampong e Boateng (2019) utilizaram uma Rede Neural Artificial para prever a intensidade das emissões de dióxido de carbono para o Brasil, entre outros países, de acordo com os parâmetros: crescimento econômico, consumo de energia, pesquisa e desenvolvimento, desenvolvimento financeiro, investimento estrangeiro, industrialização, urbanização e abertura comercial. A estrutura neural artificial

utilizada foi a *Feed Forward Back Propagation* (FFBP). Os resultados indicaram que a intensidade brasileira de emissões de dióxido de carbono tem uma tendência crescente e que a urbanização foi o parâmetro de maior contribuição. Assim, o estudo contribui significativamente para a análise do comportamento das emissões de dióxido de carbono no Brasil. No entanto, os autores não previram as emissões ano a ano, nem propuseram nenhuma estratégia quantitativa para que essas emissões fossem reduzidas para atender ao Acordo de Paris.

Com base nos trabalhos encontrados na literatura, foi possível perceber que as emissões brasileiras de CO₂ têm tendência de crescimento para os próximos anos. Os estudos preditivos que relacionam as emissões brasileiras de CO₂ com outros indicadores sugerem que a urbanização e o aumento do consumo de energia favorecem as emissões de carbono no país. Isso se deve à alta dependência do Brasil de combustíveis fósseis para geração de energia. Portanto, os autores sugerem que o governo brasileiro deve investir em sua estrutura energética para evitar desperdícios e investir em mais fontes de energia renováveis, visando menores emissões de CO₂. No entanto, nos artigos encontrados, apesar de sugerirem uma maior contribuição dos recursos renováveis na matriz energética brasileira, não demonstram de forma quantitativa o quanto essa mudança realmente contribui para a redução das emissões brasileiras de CO₂. Portanto, a análise de cenários futuros em que a matriz energética brasileira tenha maior quantidade de recursos renováveis é necessária para determinar a viabilidade técnica e econômica dessa mudança para reduzir as emissões de CO₂.

Embora alguns estudos tenham relacionado as emissões brasileiras de CO₂ com o consumo de energia do país, é importante ressaltar que a matriz energética brasileira é bastante diversificada. Portanto, é importante um estudo que utilize as diversas fontes de energia no Brasil como indicadores. Isso porque, essa subdivisão, aliada a um método capaz de classificá-los, permitirá maior compreensão de quais recursos energéticos devem ser substituídos prioritariamente por renováveis. Uma vez que o objetivo de classificar e modificar os indicadores que mais contribuem para as emissões de CO₂ no Brasil é motivado pelo desenvolvimento sustentável, é necessário considerar as queimadas em biomas brasileiros, como a Floresta Amazônica. Esse indicador ainda não foi investigado na literatura em relação ao seu

impacto nas emissões brasileiras de dióxido de carbono. Entretanto, a redução das queimadas pode reduzir as emissões de CO₂ ao mesmo tempo em que contribui com o meio ambiente.

Devido à complexidade da matriz energética brasileira e a relação não linear entre as emissões de CO₂ e os indicadores de um país (DOZIC; UROSEVIC, 2019), as Redes Neurais Artificiais (RNAs) possuem grande potencial na solução deste problema. As RNAs são modelos computacionais que se baseiam na estrutura e interconexão presentes nos neurônios biológicos (KUBAT, 1999). Eles são formados por unidades de processamento interconectadas que armazenam conhecimento, adaptando e aprendendo com o treinamento para identificar padrões (GURNEY, 2018). As RNAs podem resolver, com qualidade, inúmeros problemas envolvendo sistemas não lineares, análise de dados, modelagem, simulação, reconhecimento de padrões, entre outros, e fornecer os melhores resultados em relação aos sistemas tradicionais (DOZIC; UROSEVIC, 2019; FAYED et al., 2019; POZNYAK; CHAIREZ; POZNYAK, 2019). Portanto, escolhemos as Redes Neurais Artificiais como modelo preditivo para as emissões brasileiras de CO₂.

Com o objetivo de contribuir com a literatura existente sobre as emissões brasileiras de CO₂, esse trabalho se propõe a prever as emissões brasileiras de CO₂ entre 2019 e 2030, a fim de relacionar essas emissões com indicadores potencialmente capazes de influenciá-las. A partir daí, será possível propor e analisar cenários futuros com base na modificação de indicadores para determinar quantitativamente seu impacto nas emissões brasileiras de CO₂. O estudo desses cenários pode ajudar o governo brasileiro a propor medidas concretas em busca da redução dessas emissões. Além disso, nosso modelo pode ser facilmente modificado para atualizar os dados de entrada e incluir novos indicadores de acordo com o desenvolvimento das políticas energéticas brasileiras. Portanto, o modelo de RNA desenvolvido nessa pesquisa contribui significativamente para o estado da arte, uma vez que oferece a possibilidade de analisar de forma quantitativa a influência de diferentes cenários econômicos e ambientais nas emissões brasileiras de dióxido de carbono.

1.1. OBJETIVO

Determinar o impacto quantitativo que a substituição parcial dos combustíveis fósseis pelos renováveis e a redução das queimadas nos biomas brasileiros possuem nas emissões de CO₂ do Brasil.

2. REVISÃO BIBLIOGRÁFICA

2.1. CRESCIMENTO DO CONSUMO ENERGÉTICO

É notável o aumento da demanda energética mundial impulsionada pelo crescimento populacional, econômico e industrial do planeta (ABE; AJENIFUJA; POPOOLA, 2019; MASON; DUGGAN; HOWLEY, 2018). Nos últimos 30 anos, o consumo de energia primária aumentou em cerca de 85%, devido ao aumento da demanda energética de 512,49% e 491,83% em países como a China e a Índia, respectivamente (LEO et al., 2020). Estima-se que 87% da matriz energética global é abastecida por combustíveis fósseis não renováveis, como o petróleo, o gás natural e o carvão mineral (ABOKYI et al., 2019). O consumo desses combustíveis se intensificou nos últimos 100 anos, pois eles possuem alta densidade energética, facilidade de transporte e armazenamento. No entanto, uma matriz energética global dependente de fontes não renováveis possui 4 problemas que devem ser solucionados, sendo eles (MASON; DUGGAN; HOWLEY, 2018):

- 1) Esgotamento das fontes não renováveis;
- 2) Produção de gases potencializadores do Efeito Estufa;
- 3) Produção de poluentes atmosféricos que causam danos à saúde dos seres vivos;
- 4) Incorporação de fontes de energia renováveis e de alta eficiência.

O crescimento do consumo energético global, juntamente com os problemas do fornecimento de energia baseado, majoritariamente, em uma matriz energética fóssil, vem encorajando estudos e debates no meio acadêmico e político, a fim de se criar estratégias que garantam o crescimento econômico a partir de uma matriz energética mais limpa, eficiente e renovável (GASPAR; MARQUES; FUINHAS, 2017; BRETSCHGER, 2017; SONG et al., 2018; MERINO-SAUM et al., 2018; ANDREONI, 2020). Essas novas estratégias, intensificadas nos últimos anos, aliadas ao consumo responsável de energia tem contribuído para o melhor aproveitamento dos recursos energéticos de países mais desenvolvidos, como os EUA, alguns do Reino Unido e a Irlanda (ANDREONI, 2020). Do contrário, os países em desenvolvimento, como a China, a Índia e os mais afetados pelas crises econômicas globais (Grécia, Espanha e Romênia) têm apresentado um menor

ganho em eficiência energética, além de pouca utilização de fontes menos poluentes (LEO et al., 2020; ANDREONI, 2020).

Os possíveis impactos que podem ser causados pelo crescimento socioeconômico e do consumo energético global estão gerando cada vez mais discussões no âmbito científico (MOREAU; VUILLE, 2018; MAHMOOD; AHMAD, 2018; HALKOS; POLEMIS, 2018; PAO; CHEN, 2019). Apesar de não haver um consenso a respeito de todas as interações e consequências entre a economia global e a demanda energética, não há dúvidas de que é imprescindível que a matriz energética mundial se torne mais limpa e renovável, aliada às tecnologias energéticas mais eficientes.

2.2. Emissões de poluentes atmosféricos provenientes da queima dos combustíveis fósseis

A atmosfera terrestre é constituída, em baixa concentração, dentre outras substâncias, por aerossóis carbonáceos, como o carbono elementar e o refratário (CONTINI; VECCHI; VIANA, 2018). Já se sabe que esses componentes, em alta concentração, afetam a qualidade do ar, a sua visibilidade, o clima e a saúde humana, sendo que esses efeitos nocivos podem alcançar escalas globais (YAN et al., 2019; SALMA et al., 2017). Na última década, as emissões de poluentes atmosféricos e de CO₂ aumentaram significativamente, e o maior contribuinte nessas emissões é o setor de transporte, que corresponde ao segundo maior consumidor de energia global (ALIMUJIANG; JIANG, 2020). Para abastecer essa e as outras atividades industriais e socioeconômicas do mundo, utiliza-se na maior parte, a queima dos combustíveis fósseis, como os derivados de petróleo, o carvão mineral e o gás natural, juntamente com a biomassa. Entretanto, a queima dos combustíveis fósseis representa a maior fonte de emissões de poluentes atmosféricos (YAN et al., 2019). Dessa forma, essas substâncias (aerossóis carbonáceos, monóxido de carbono, dióxido de carbono, óxidos de nitrogênio e hidrocarbonetos aromáticos policíclicos) podem causar grandes malefícios à qualidade do ar e à saúde humana, além de impactos no clima global (YAN et al., 2019; ANDREAE, 2019).

Os óxidos de nitrogênio (NO_x) possuem diversas formas e são os principais poluentes do ar gerados pela queima de combustíveis. Entretanto, os mais emitidos são, geralmente, o NO (5%) e o NO₂ (95%) (GHOLAMI et al., 2020). Diversos

problemas de saúde podem ser causados pelas emissões de NO_x, como irritações no sistema respiratório, nos olhos, aperto no tórax, náuseas e dores de cabeça. Além dos impactos na saúde humana, a poluição por NO_x também agride o meio ambiente, causando chuvas ácidas, neblinas, a depleção da camada de ozônio e a poluição fotoquímica (RESITOGU, 2018; WEI et al., 2019; GHOLAMI et al., 2020). Devido a todos esses impactos, as emissões de NO_x são restringidas em diversos países e seguem algumas normas como a Euro V e a Euro VI (GHOLAMI et al., 2020). Todavia, estudos demonstraram que a concentração dos óxidos de nitrogênio em grandes cidades vem aumentando significativamente e ultrapassando os limites estabelecidos pelas normas em alguns casos (SIMMONS; SEAKINS, 2012; DELL; MOSELEY; RAND, 2014; VERHELST et al., 2019; SHCHEKLEIN; DUBININ, 2020). Alguns autores relacionaram ainda, os óxidos de nitrogênio, de enxofre e o monóxido de carbono com o infarto do miocárdio (CESARONI et al., 2014; AKABARZZADEH et al., 2018), demonstrando mais uma vez os riscos à saúde trazidos por esses poluentes. Sendo assim, faz-se necessária uma busca mais efetiva pela redução, controle e se possível, a eliminação dessas emissões, a fim de se preservar a saúde humana e o meio ambiente.

2.3. EMISSÕES DE CO₂ E O AQUECIMENTO GLOBAL

Além das emissões de poluentes, a queima dos combustíveis fósseis libera na atmosfera grande quantidade de CO₂ e de outros gases potencializadores do efeito estufa (ABOKI et al., 2019; VITA et al., 2019; REN et al., 2020b). Estima-se que nos últimos 50 anos a concentração de dióxido de carbono na atmosfera tenha aumentado em 30%, além de outros gases do efeito estufa, contribuindo para o aquecimento global e para a diminuição da qualidade do ar (HERBERT; KRISHNAN, 2016). Mesmo com os diversos alertas globais para as altas emissões de gás carbônico, a Agência Internacional de Energia (IEA) informou que entre os anos de 2000 e 2017 mais de 9 bilhões de toneladas foram emitidas (IEA, 2018), demonstrando assim uma tendência crescente para essas emissões. Ao final de 2017, mensurou-se que a concentração dos gases potencializadores do efeito estufa na atmosfera era de 407 ppm, representando o maior valor dos últimos 800 mil anos, além da temperatura global ter aumentado em 1,1 °C em comparação ao período pré-industrial, momento em que houve um grande aumento no consumo de

combustíveis (ZHOU et al., 2018). O aumento excessivo e acelerado da temperatura do planeta afeta diretamente o clima de inúmeras regiões, intensificando a frequência e a potência dos desastres ambientais que podem prejudicar os sistemas naturais e humanos, além de causar mortes e impactos econômicos (PARRY et al., 2004; FISCHER et al., 2005; SMITH et al., 2014; ZHOU et al., 2018).

2.4. CONSEQUÊNCIAS DO AQUECIMENTO GLOBAL

Grande parte da comunidade científica concorda que o aquecimento global se intensificou nos últimos anos e aumentará devido à queima dos combustíveis fósseis que liberam, dentre outros gases, o dióxido de carbono (STOCKER et al., 2013; ZHANG; ZHOU, 2020). Esse aumento na temperatura do planeta já impactou negativamente ecossistemas, a economia global e a sociedade humana de diversas maneiras, principalmente por ter causado mudanças extremas no clima de diversas regiões (ZHANG; ZHOU, 2020; LIU et al., 2020). A China, por exemplo, é uma região bastante vulnerável ao aquecimento global devido a sua alta população e a sua complexa topografia (ZHANG; ZHOU, 2020; HUANG et al., 2013; ZHOU et al., 2012). Para a China, estima-se que desde 1990, os desastres ambientais causam prejuízos econômicos maiores que 200 bilhões de yuans por ano, além de atingirem outras regiões (ZHANG; ZHOU, 2020).

Outra grande preocupação em relação ao aquecimento global diz respeito ao derretimento das geleiras, o aumento do nível do mar e de sua temperatura (WOO et al., 2019; KHATUA; JANA; KAR, 2020; TURKI et al., 2020). Em particular, a Península da Antártica vem sendo afetada pelo aquecimento global que causa grande derretimento em suas geleiras, além de alterar a harmonia do ecossistema local (WOO et al., 201). O aumento da temperatura do mar causa mudanças físicas e químicas na água, alterando o fluxo de carbono e de alimentos, podendo colapsar o ecossistema marítimo local (GARCIA et al., 2019). Apesar do aumento do nível do mar não ser uniforme em todo o mundo e dependente de inúmeros fatores, a sua maior causa é o aumento da temperatura do planeta que causa degradação das geleiras e calotas polares (CARVALHO; WANG, 2019). Nesse contexto, observou-se que o Oceano Índico vem aumentando o seu nível de forma bastante acelerada,

tendo causado, nos últimos anos, inundações e tempestades devastadoras em regiões costeiras (THOMPSON et al., 2016; WANG, 2019).

Além dos impactos causados nos mares e nas regiões costeiras, o aquecimento global afeta, significativamente, os ecossistemas terrestres. Sabe-se que as alterações climáticas afetam os processos fisiológicos das árvores, afetando o crescimento, a reprodução e a distribuição delas (YASMEEN et al., 2019). O crescimento radial das árvores é de fácil observação e fornece inúmeras informações a respeito do seu desenvolvimento, idade, comportamento de espécies, ciclo de vida, dentre outras, além de ser extremamente sensível às mudanças climáticas (YASMEEN et al., 2019; TRUETTNER et al., 2018; CAO et al., 2018). Por esse motivo, o número de estudos sobre o crescimento radial das árvores, que relacionam o aquecimento global com as florestas vem aumentando. Esses estudos visam compreender melhor como cada espécie é afetada e aumentar o conhecimento sobre esse ecossistema, além de prever os principais impactos que eles podem sofrer (YASMEEN et al., 2019).

Uma vez que se entenda a sensibilidade das florestas com o aquecimento global, fica claro o perigo que existe em relação à agricultura e à produção mundial de alimentos. O projeto HAPPI (*Half a degree Additional warming, Projection, Prognosis and Impacts*) desenvolveu uma ferramenta para analisar os impactos que o Acordo de Paris terá, se cumprido, sobre diversas áreas do planeta (MITCHELL et al., 2017; RUANE; PHILLIPS; ROSENZWEIG, 2018). Atualmente, o projeto vem sendo utilizado para analisar, principalmente, os impactos que o aquecimento global possui na agricultura mundial para o abastecimento de alimentos (CHEN; ZHANG; TAO, 2018; FAYE et al., 2018; GAUPP et al., 2019; SCHLEUSSNER et al., 2018). Acredita-se que a agricultura será o setor mais afetado, negativamente, pelo aquecimento global, já tendo sido bastante afetada pelas variações climáticas em diversas regiões (GAUPP et al., 2019). Em 2018 a FAO (*Food and Agriculture Organization of United Nation*) estimou que mais de 10% da população mundial vive em condições de subnutrição (FAO, 2018) além disso, espera-se que em 2050 a demanda mundial de alimentos aumentará em 40% devido ao crescimento populacional (GAUPP et al., 2019;

VERSCHUUREN, 2016), significando que mais pessoas deverão ser afetadas pela fome e desnutrição.

Sabe-se que o arroz é um dos alimentos mais básicos para a maioria da população (LIU et al., 2020; MUTHAYYA et al., 2014) e que a China detém cerca de 1/3 da produção mundial (LIU et al., 2020). Entretanto, o país é um dos mais sensíveis e afetados pelo aquecimento global (ZHANG; ZHOU, 2020), o que tem prejudicado a estabilidade e a segurança do abastecimento de arroz (LIU et al., 202). Além disso, não é só a produção de arroz que tem sua segurança e estabilidade em risco. Isso porque a agricultura e o sistema de abastecimento de alimentos a nível global estão cada vez mais interligados, proporcionando que o aquecimento global ocorrendo simultaneamente, em diversas áreas do planeta, potencialize os impactos na agricultura, colocando em risco toda a segurança alimentar do mundo (GAUPP et al., 2019). Esses impactos sofridos pela agricultura, além de aumentarem a fome e a desnutrição no planeta podem causar conflitos entre países vizinhos. A região árida central da Ásia, devido a sua falta de umidade, exige altas quantidades de água para o seu sistema de irrigação, tornando esse recurso essencial no desenvolvimento socioeconômico da região (LI et al., 2020). Desde o século XX, essa região vem sofrendo os danos causados pelo aquecimento global, que tem aumentado a demanda por água na região e afetado a sua distribuição natural, causando a desertificação de algumas áreas e a salinização do solo, além de gerar conflitos entre países vizinhos (LI et al., 2020; ISSANOVA et al., 2017). Com o intenso crescimento populacional da região e a maior demanda de água causada pelo aquecimento global, esse recurso será disputado por diversos setores, como o consumo primário, projetos de energia, dentre outros, além da própria agricultura que será reduzida significativamente (LI et al., 2020; CHEN et al., 2018). Sendo assim, fica claro que o constante aumento na temperatura do planeta intensifica cada vez mais os seus efeitos nocivos aos ecossistemas do mundo e à sociedade humana. Sendo assim, faz-se necessária a busca por soluções que reduzam o aquecimento global. Dessa forma, o equilíbrio e a segurança da vida no planeta poderão ser mantidos.

2.5. ESTRATÉGIAS E TECNOLOGIAS PARA A REDUÇÃO DO CO₂

Sabendo-se que o dióxido de carbono e outros gases liberados na queima dos combustíveis fósseis intensificam o aquecimento global, é de fundamental importância o desenvolvimento de soluções para reduzir essas emissões. Tanto o desenvolvimento tecnológico, quanto o aumento da consciência ambiental nas últimas décadas, têm motivado o surgimento de novos combustíveis e projetos energéticos mais eficientes e menos poluentes (ABE; AJENIFUJA; POPOOLA, 2019; VITA et al., 2019).

2.6. ENERGIA SOLAR

Dentre as fontes de energia, a solar é a de maior potencial de desenvolvimento, sendo abundante e bem distribuída no planeta (REN et al., 2020a). A indústria fotovoltaica em 2018 já representava mais de 20% da energia renovável do mundo, podendo aumentar em mais de 40 vezes a sua geração de energia até 2050 (REN et al., 2020a). Nos Estados Unidos, havia quase 1,6 milhões de instalações solares em 2018, além de grande apoio público a respeito dessa tecnologia, possibilitando que até 2050 ela seja a maior geradora de eletricidade no mundo (HENG et al., 2020). Atualmente, as tecnologias de geração de energia solar são focadas na produção fotovoltaica, tanto para residências quanto para outros consumidores (BRIESE et al., 2019; CHO; SHAYGAN; DAIM, 2019; TORABI et al., 201). Essa tecnologia fotovoltaica para a geração de energia, consiste na utilização de materiais semicondutores e efeitos fotovoltaicos que após absorverem a radiação solar convertem-na em energia elétrica para ser utilizada em diversas situações (REN et al., 2020a). Na última década, houve um aumento nos trabalhos relacionados ao aumento de eficiência da tecnologia fotovoltaica. Isso deu, em grande parte, pela necessidade de se reduzir as emissões de dióxido de carbono (HENG et al., 2020; CSEREKLYEI; QU; ANCEV, 2019; SOW et al., 2019; BEST; TRUCK, 2020).

2.7. ENERGIA EÓLICA

A energia eólica vem se desenvolvendo e desempenhando um grande papel na geração de energia elétrica da Europa, desde o início do século XXI, proporcionando o aumento de suas instalações em mais de dez vezes, devido ao apoio do Reino Unido, Alemanha e Espanha (GARRIDO-PEREZ et al., 2020). Espera-se que os

investimentos no desenvolvimento e implantação dessa tecnologia na Europa e em outras regiões contribua de forma significativa no desenvolvimento sustentável do planeta, gerando energia limpa, renovável e de baixo impacto ambiental (GARRIDO-PEREZ et al., 2020; SADEGHIANPOURHAMAMI et al., 2016; ZHANG et al., 2016). Apesar dessa tecnologia ser bastante dependente de fatores climáticos, especialmente da velocidade do vento (GARRIDO-PEREZ et al., 2020), várias regiões apresentam boas condições para explorar essa fonte de energia, como o Brasil, a China, a Europa, dentre outras (GARRIDO-PEREZ et al., 2020). Portanto, é de fundamental importância que os países que apresentam boas condições para explorar a energia eólica invistam em pesquisas e tecnologias para tornar esse método de geração de energia mais barato e eficiente, a fim de contribuir com um futuro sustentável.

2.8. COMBUSTÍVEIS RENOVÁVEIS

Sabendo-se que o setor de transporte é o segundo maior consumidor de energia e, majoritariamente, dependente dos combustíveis fósseis, há grande esforço pela comunidade científica para torná-lo livre de emissões de poluentes (ALIMUJIANG; JIANG, 2020; MICHALSKI; POLTRUM; BUNGER, 2019). Uma forma de reduzir as emissões de dióxido de carbono é a substituição dos combustíveis tradicionais pelos renováveis em que ao se renovar a safra da matéria-prima, parte do dióxido de carbono é absorvido, havendo menor contribuição no aumento da concentração desse gás na atmosfera (VITA et al., 2019; AFOLABI; LI; KECHAGIOPOULOS, 2019; HAN et al., 2019). Os Estados Unidos e o Brasil são os dois maiores produtores de etanol do mundo, sendo que esse biocombustível líquido é comercializado em alta escala (ZHAO; ZHANG; LI, 2019). Entretanto, o etanol é produzido, em sua maioria, por fontes alimentícias, como o milho, a cana-de-açúcar, o arroz, dentre outras (ZHAO; ZHANG; LI, 2019). Isso impulsionou diversas pesquisas para produzir esse combustível por fontes alternativas, garantindo a segurança e estabilidade da produção de alimentos (SUN et al., 2015). Essas alternativas consistem de biomassa lignocelulósica que podem ser convertidas a etanol a partir da ação de alguns microrganismos. Desse modo, pode-se reduzir o desvio da matéria-prima alimentícia para a produção de combustível (ZHAO; ZHANG; LI, 2019; MUNJAL et al., 2015; SAHA et al., 2015; SAINI et al., 2017).

O biodiesel também vem se destacando como combustível alternativo para reduzir as mudanças climáticas, podendo ser produzido a partir de óleos vegetais (PIRJOLA et al., 2019). Por apresentar propriedades semelhantes ao diesel derivado do petróleo, o biodiesel possui grande potencial no abastecimento do setor de transporte (SINGH et al., 2019). Além disso, possui vantagens em relação ao diesel comum já que causa menor impacto ao meio ambiente, é renovável, biodegradável, não tóxico e de alto ponto de ignição (SINGH et al., 2019; CHIDAMBARANATHAN et al., 2020). Sendo assim, é possível reduzir as emissões de CO₂ e de poluentes atmosféricos a partir da maior utilização de combustíveis renováveis, como o biodiesel (SINGH et al., 2019; TANG; GU; CHEN, 2013).

2.9. O GÁS HIDROGÊNIO COMO COMBUSTÍVEL

O hidrogênio é o elemento químico mais leve e abundante do universo, compondo cerca de 90% da matéria existente. Sua molécula gasosa é uma substância não tóxica e de queima limpa, liberando apenas água. Portanto, é uma fonte de energia limpa e possui cerca de 120 MJ por kg (ABE; AJENIFUJA; POPOOLA, 2019; MAH et al., 2019). Dessa forma, o gás hidrogênio apresenta-se como uma das alternativas mais promissoras aos combustíveis fósseis (AYODELE; MUNDA, 2019). A utilização de hidrogênio como fonte primária de energia tem se tornado atrativa para os pesquisadores, porque o hidrogênio pode ser obtido a partir de fontes renováveis, como o etanol e biomassas (ABE; AJENIFUJA; POPOOLA, 2019; VITA et al., 2019).

A ideia de tornar o gás hidrogênio como o principal combustível mundial é chamada de "Economia do Hidrogênio". Esse termo surgiu por volta de 1970, envolvendo pesquisas a respeito da utilização, produção, transporte e armazenamento do gás hidrogênio (AYODELE; MUNDA, 2019; LIU et al., 2019; SINIGAGLIA et al., 2019). Com o avanço das pesquisas nos últimos anos, as vantagens econômicas e ambientais do gás hidrogênio vêm se confirmando e se popularizando, devido a maior consciência ambiental e o marketing dos carros elétricos a base de células de hidrogênio (MICHALSKI; POLTRUM; BUNGER, 2019; VITA et al., 2019; MURITALA et al., 2019). Vale ressaltar que o gás hidrogênio já vem sendo utilizado na produção de fertilizantes, metanol e na purificação de combustíveis a base de petróleo, como a

gasolina e o diesel (FAHIM; AL-SAHHAF; ELKILANI, 2012). Em 2011, a produção mundial de gás hidrogênio chegava a 50 milhões de toneladas por ano (ARMAROLI; BALZANI, 2011), sendo estimado que de 2017 a 2023 o crescimento na produção de hidrogênio passará de 129,25 a 183,34 bilhões de dólares (MAH et al., 2019), evidenciando o potencial econômico que esse recurso possui.

Devido às consequências do aquecimento global acelerado já sentidas em todo o mundo, faz-se necessária uma mudança, sem mais atrasos, na matriz energética global, a fim de torná-la menos dependente dos combustíveis fósseis. Para isso, há inúmeras alternativas de combustíveis e tecnologias que produzem energia limpa e renovável. A escolha de qual será a melhor opção dependerá das estratégias políticas e energéticas de cada país, sendo necessária a avaliação de suas particularidades e da disponibilidade de seus recursos naturais.

2.10. METAS DA CONFERÊNCIA DAS PARTES DA CONVENÇÃO QUADRO DAS NAÇÕES UNIDAS SOBRE MUDANÇA NO CLIMA

A Conferência das Partes (COP - *Conference of the Parties*) é a entidade da Convenção Quadro das Nações Unidas sobre Mudança no Clima (UFCCC - *United Nations Framework Convention on Climate Change*) encarregada de apoiar os países na resposta às ameaças da mudança climática. O secretariado surgiu em 1992, em Geneve, e a partir de 1995 passou a ser realizado em Berlim. Atualmente, a COP possui 197 países e os reúne, anualmente, tomando decisões que só são aceitas se forem unânimes, e que se tornam soberanas para todos os membros. O seu objetivo é estabilizar a concentração de gases de efeito estufa na atmosfera, em níveis seguros, para que o sistema climático e os ecossistemas consigam adaptar-se, possibilitando o desenvolvimento sustentável. Para isso, o secretariado provê competência técnica, análises e revisões das informações sobre mudanças climáticas (COP, 2020).

2.11. PROTOCOLO DE KYOTO: 1997

O acelerado aquecimento global e seus impactos nos sistemas climáticos e nos ecossistemas ganharam destaque no debate científico e internacional (MAAMOUN, 2019). Pois, além dos efeitos negativos para os ecossistemas naturais e para as atividades socioeconômicas, há complexidade em suas causas e muitas incertezas sobre as suas consequências futuras, devido ao crescimento da poluição do ar, que já possui 70% a mais de gases de efeito estufa em relação há 40 anos (MAAMOUN, 2019; BLANCO et al., 2014). Tratando-se de um problema global, desde 1970, houve aumento nos acordos e políticas internacionais para tentar frear o crescimento exponencial da poluição atmosférica, com destaque para o Protocolo de Kyoto (MAAMOUN, 2019; LIVERMORE; REVESZ, 2014).

O Protocolo de Kyoto foi realizado em 1997 e estabeleceu uma meta, jurídica, aos países membros da COP de redução de 5% das emissões de gases de efeito estufa em relação ao período de 1990 (MAAMOUN, 2019; MIYAMOTO; TAKEUCHI, 2019). A fim de facilitar esse objetivo, o protocolo ofereceu ferramentas, como o Comércio Internacional de Emissões, a Implementação Conjunta e auxílios ao Desenvolvimento Limpo (MAAMOUN, 2019; MIYAMOTO; TAKEUCHI, 2019). Entretanto, as diretrizes estabelecidas no Protocolo de Kyoto não foram completamente cumpridas, o que levou alguns anos mais tarde ao surgimento de estudos sobre os impactos do acordo, a fim de se identificar pontos a serem melhorados em acordos futuros (MAAMOUN, 2019; MIYAMOTO; TAKEUCHI, 2019; ALMER; WINKLER, 2017; GRUNEWALD; MARTINEZ-ZARZOSO, 2016). Foi concluído, nesses estudos, que apesar dos compromissos acordados internacionalmente não terem sido cumpridos em sua totalidade, a partir do Protocolo de Kyoto, as emissões de poluentes foram reduzidas em 7% em relação a um cenário da "Ausência de Kyoto" (MAAMOUN, 2019). Inclusive, após o firmamento desse acordo, houve crescimento nos pedidos de patentes em relação às tecnologias sustentáveis para a geração de energia (solar e eólica) (MIYAMOTO; TAKEUCHI, 2019; JOHNSTONE; HASCIC; POPP, 2010). Essa conclusão mostra que as políticas internacionais coletivas possuem efeito na redução da emissão dos gases de efeito estufa. Porém, para se alcançar o potencial máximo previsto pelas diretrizes acordadas, faz-se necessário um total compromisso pelos países membros da COP, além de mecanismos e metas mais rígidas.

2.12. O ACORDO DE PARIS: 2015

A Conferência das Partes continua sendo o palco principal para o desenvolvimento de respostas e mecanismos frente ao contínuo crescimento das emissões de poluentes atmosféricos e do aquecimento global (BACKSTRAND; LOVBRAND, 2019). A COP de 2015, em Paris, foi considerada a mais bem-sucedida conferência sobre mudanças climáticas de todos os tempos (KINLEY, 2017), diferentemente da frustrante e desambiciosa COP de 2009, em Copenhague (TOBIN et al., 2018). Antes mesmo da realização da COP de 2015, foi requisitado aos países que enviassem metas para o clima, que ficaram conhecidas como "Pretensão de Contribuições a Nível Nacional" ou INDCs (*Intended Nationally Determined Contributions*), que foram firmadas no chamado Acordo de Paris (TOBIN et al., 2018; RAJAMANI, 2016). A introdução das INDCs foi de fundamental importância no sucesso da conferência, principalmente por enfatizar a necessidade da colaboração individual de cada país, de acordo com suas capacidades, para se alcançar resultados a nível global (TOBIN et al., 2018).

Diante do crescente acúmulo dos gases de efeito estufa na atmosfera, emitidos por ações humanas, e do aumento da temperatura global, o Acordo de Paris firmou a meta de limitar o aquecimento entre 1,5 °C e 2 °C em relação ao período pré-industrial (LYON, 2018; NATIONS, 2016). Entretanto, as projeções indicam que a temperatura média mundial aumentará entre 2,7 °C - 5,2 °C até 2100, podendo ultrapassar a meta de 1,5 °C ainda em 2026 (LYON, 2018; NATIONS, 2016). Apesar dessas previsões preocupantes, pouca ação foi tomada para intensificar os esforços na diminuição das emissões dos gases de efeito estufa (LYON, 2018). Em 2018, a Organização Meteorológica Mundial das Nações Unidas mostrou que as duas últimas décadas incluem 18 dos 20 anos mais quentes desde os valores aferidos em 1850 (TOLLIVER; KEELEY; MANAGI, 2020). Além disso, 2019 registrou o recorde de derretimento no manto de gelo da Groelândia, havendo a possibilidade do nível do mar ser elevado em mais de 2 metros durante o século XXI (TOLLIVER; KEELEY; MANAGI, 2020; BAMBER et al., 2019). Sendo assim, é imprescindível que os países membros da COP honrem as suas INDCs, todas as diretrizes aprovadas no Acordo

de Paris e que a população opte por um estilo de vida mais sustentável, consumindo produtos e serviços mais "verdes" (BAUER; MENRAD, 2019)). Somente com o esforço coletivo será possível reduzir as taxas das emissões de dióxido de carbono, garantindo aos ecossistemas uma adaptação natural às mudanças climáticas. Caso novos combustíveis e tecnologias para a geração de energia sustentável, menos poluentes e mais eficientes, não recebam o devido investimento, o acelerado aquecimento global trará muitas perdas aos ecossistemas naturais e à sociedade.

2.13. POLÍTICAS ENERGÉTICAS E O ACORDO DE PARIS

Por questões técnicas, ambientais e políticas, a energia sustentável é a essência do crescimento econômico e das mudanças climáticas. Isso vem provocando um encorajamento por parte dos governos a desenvolverem matrizes energéticas mais limpas e sustentáveis (BAIARDI, 2020). Políticas Energéticas (PE) são caminhos e diretrizes feitos por uma entidade política, como os governos, para o desenvolvimento do setor energético, envolvendo a sua produção, distribuição e consumo (DOZIC; UROSEVIC, 2019). Sem todo esse planejamento por parte dos governos não é possível garantir a demanda energética de um país, muito menos de forma limpa e sustentável. Na União Europeia, estima-se que 7,8% das famílias não possuem energia para manterem suas casas aquecidas, enquanto 7% está em atraso com suas contas. Dessa forma, um dos principais objetivos das Políticas Energéticas é reduzir a pobreza energética com segurança econômica e ambiental (PRIMC; SLABE-ERKER, 2020). Já é conhecido que as PE possuem grande importância na transição entre uma matriz energética fóssil para uma renovável (PRIMC; SLABE-ERKER, 2020; BANERJEE et al., 2017). De fato, são elas que podem impulsionar de forma efetiva o surgimento de novos combustíveis e tecnologias, já que isso demanda altos investimentos. A Itália é o 8º maior emissor de gases de efeito estufa e o seu setor energético era responsável por 82,4% dessas emissões em 2012 (BAIARDI, 2020). Mas a partir da intensificação em PE para a redução de gases poluentes, houve um crescimento extraordinário no setor energético sustentável, e espera-se que em 2050 a Itália torne-se o país líder em geração energética sustentável da União Europeia (BAIARDI, 2020; ALBERINI et al., 2018).

O Acordo de Paris, com suas metas e diretrizes, é soberano aos países membros da COP, além de que todos entregaram suas estratégias individuais para o combate das mudanças climáticas aceleradas. Dessa forma, é imprescindível que os países elaborem PE que garantam o abastecimento de suas demandas energéticas de forma a reduzirem suas emissões de poluentes. De outra forma, não será possível atingir essa redução em um nível significativo para que os ecossistemas se adaptem de forma natural às mudanças climáticas, trazendo um futuro incerto para o desenvolvimento e qualidade de vida no planeta.

2.14. O BRASIL E O SEU PLANO NACIONAL DE ENERGIA PARA 2050

Com o intuito de atender à crescente demanda energética no país, aproveitando da melhor forma possível seus recursos energéticos, o Ministério de Minas e Energia do Brasil, em conjunto com a Empresa de Pesquisas Energéticas (EPE), publicou em 2013 o Termo de Referência para o Plano Nacional de Energia 2050. A partir dessa norma técnica, será desenvolvida a base para a formulação de políticas públicas. Essas políticas têm o objetivo de expandir a oferta energética no Brasil, observando as premissas básicas de segurança energética para a ampliação do acesso à energia pela população, geração de emprego e renda, redução das desigualdades regionais, desenvolvimento tecnológico nacional, diversificação da matriz energética, priorizando os recursos renováveis para garantir a sustentabilidade ambiental, além de moderar os preços e tarifas dos recursos energéticos (MME, 2018a).

O desenvolvimento do PNE 2050 parte da construção e avaliação dos cenários econômicos futuros. Esse estudo é imprescindível, pois esses cenários influenciarão nos modelos preditivos de demanda e oferta energética, além de trazer consistências a qualquer outra projeção do PNE 2050. Para tais cenários, não se pode deixar de fora as projeções da população, domicílios, PIB, PIB *per capita* e de cada setor, como transporte, industrial, agronegócio, dentre outros (MME, 2013).

2.15. A PRODUTIVIDADE BRASILEIRA E OS SEUS INDICADORES

O aumento da produtividade do país impacta diretamente o seu crescimento econômico. Entre os anos de 2000 a 2013, houve um crescimento do PIB, cerca

3,6% a.a. Entretanto, esse crescimento econômico impulsionado pelas altas exportações de *commodities* e pelo consumo interno superaquecido vem diminuindo. Para essa avaliação de crescimento econômico, a Produtividade Total dos Fatores (PTF) é um importante indicador, e na última década foi mensurado em -0,71% a.a., que é bastante inferior ao de outros países desenvolvidos e em desenvolvimento. Sendo assim, o PNE 2050 busca, dentre outros objetivos, destravar o crescimento da produtividade. Para isso, é preciso identificar os principais desafios, a partir das projeções de cenários de produtividade, com premissas nas políticas econômicas utilizadas pelo PNE 2050, que impactarão de forma expressiva na oferta de energia brasileira (MME, 2018b).

A elaboração correta de projeções para a PTF exige o conhecimento sobre a sua evolução histórica, bem como os principais indicadores que afetam a PTF. Esses indicadores podem ser resumidos em 5 itens:

2.15.1 Inovação:

A ligação entre a produtividade de um país e os investimentos em inovação é bem clara. Entretanto, é necessário analisar de forma correta quais são os principais esforços e inovações que devem ser realizados para garantirem, de fato, um aumento significativo na produtividade. Pode-se classificar a inovação como a criação de novos produtos e serviços, assim como o aperfeiçoamento dos já existentes. Um importante incentivo à inovação é o investimento em Pesquisa e Desenvolvimento (P&D), seja pelo governo ou pelas empresas. Sabe-se que um parque tecnológico e de pesquisa científica pode gerar o conhecimento que é essencial no crescimento econômico. Nos últimos anos, o Brasil tem aumentado o seu número de pós-graduados e a participação destes em pesquisas indexadas (MME, 2018c). Entretanto, se comparado a outros países, o investimento em P&D do Brasil, ainda é pequeno, conforme a Figura 1.




Figura 1. % do PIB investido em P&D pelos países no ano de 2016. Fonte: Ministério de Minas e Energia (2019).

A partir da Figura 1, percebe-se que o Brasil fica atrás de outros 10 países em termos de investimento em P&D a partir do percentual do PIB. Apesar da dificuldade em quantificar os resultados dos investimentos em P&D, caso o Brasil deixe de aumentar de forma adequada os seus investimentos nessa área, o país continuará dependendo da importação de tecnologia, perdendo oportunidades para exportá-la e oferecê-la internamente, aquecendo a sua economia.

2.15.2 Educação

O amplo acesso à educação e a informação aumenta a qualificação do capital humano. Esse recurso, por sua vez, participa intimamente do crescimento

econômico de um país. Nesse contexto, a baixa qualidade da educação gera mão de obra pouco qualificada, inibindo o desenvolvimento da nação (LINS; ARBIX, 2011). Para que o profissional brasileiro se torne mais qualificado, não há dúvidas de que é necessário a universalização do ensino. No entanto, a qualidade dessa educação não pode ser deixada de lado, caso contrário, o número de profissionais desqualificados aumentará sem haver um aumento significativo no crescimento econômico. Apesar da escolaridade média do Brasil ter aumentado entre 1997 e 2014, e dos gastos públicos em educação, isso não impactou de forma significativa a produtividade do país (VELOSO; BONELLI; CASTELAR, 2017). Sendo assim, o tempo de estudo do profissional deve estar aliado à qualidade de ensino e da capacidade do setor produtivo em absorver esses profissionais para que seja obtida alguma melhoria na produtividade do país.

2.15.3 Sistema Tributário:

A arrecadação de impostos pode prover os serviços públicos, gerando o bem-estar social. Todavia, caso seja mal formulada, representará uma dificuldade ao desenvolvimento da economia, como acontece no Brasil (BANK, 2019). Isso ocorre devido ao sistema tributário brasileiro ser complexo e mal "desenhado", o que prejudica o setor produtivo do país. A literatura indica opções em que o Brasil pode aumentar a sua eficiência produtiva a partir de simples correções nos incentivos agressivos de impostos sobre consumo e produção, principalmente o Imposto Sobre Circulação de Mercadorias e Serviços (ICMS). Os caminhos para uma melhor estrutura do sistema tributário brasileiro já são conhecidos. Porém, segui-los é altamente desafiador, já que isso afetaria inúmeras questões importantes para os políticos, como as relações entre os governos estaduais e municipais.

2.15.4 Ambiente de Negócios:

O ambiente de negócios dos setores produtivos, bem como os tributos e a burocracia do país, impacta diretamente o seu desenvolvimento. Dessa forma, o aumento na qualidade desses ambientes refere-se a qualquer ação que simplifique o ciclo de vida do setor produtivo (NEGRI, 2015). A relação entre a produtividade e o ambiente de trabalho não é linear. Todavia, com base no relatório do Banco Mundial

(*Doing Business*) é possível tirar algumas conclusões. Nele, diversos países são avaliados com base em diversos indicadores envolvidos com o ciclo de vida empresarial, como o pagamento de impostos, acesso à eletricidade, facilidade na abertura do negócio, obtenção de créditos, dentre outros. Dentre 190 países avaliados pelo *Doing Business* de 2019, o Brasil ocupou a 109ª posição, apresentando dificuldades burocráticas, baixo índice global de competitividade, ficando atrás inclusive de países latino-americanos. Sendo assim, é necessária uma mudança nas regulações as quais as empresas estão sujeitas para que a qualidade do seu ambiente de negócios aumente, contribuindo para o crescimento econômico e produtivo do Brasil nos próximos anos.

2.15.5 Investimentos em Infraestrutura:

A capacidade produtiva de um país é dependente dos seus investimentos em infraestrutura, que também podem contribuir com a eficiência de produção. Em 2018, o Brasil ocupou a 81ª posição em um ranking de 140 países, em relação a infraestrutura produtiva (SCHWAB, 2018). Essa área engloba principalmente o setor de transportes e de saneamento básico, com acesso à rede de esgotos e distribuição de água. Desse modo, um sistema produtivo bem estruturado e estável aumenta o desejo e a confiança nos investimentos, modernizando a infraestrutura já existente e aumentando a produção do país.

De modo geral, para as projeções dos cenários econômicos brasileiros até 2050 é indispensável a avaliação prévia do seu potencial produtivo. Esse, por sua vez, depende, majoritariamente dos 5 indicadores brevemente discutidos. No PNE 2050 estão sendo considerados 2 cenários econômicos. O primeiro é o caso do melhor desenvolvimento desses 5 indicadores e da produtividade brasileira, enquanto que o segundo representa uma situação menos favorável, com a piora das contas públicas, baixos investimentos e queda na qualidade do sistema produtivo do país.

2.16. DEMANDA ENERGÉTICA BRASILEIRA ATÉ 2050

Conhecendo-se os principais indicadores que afetam a produtividade do país é possível projetar seus cenários de crescimento econômico. Esses, por sua vez,

influenciam o consumo energético, sendo necessário identificar e antecipar eventos que possam distribuir de forma mais eficiente os recursos energéticos. Dessa forma, as análises de demanda energética são a base para a criação de políticas e estratégias, que a partir das reservas dos recursos energéticos, promoverão melhorias no relacionamento da sociedade brasileira com a energia (MME, 2018c)

As análises do PNE 2050 têm como base o ano de 2015 e são realizadas até o ano de 2050. Com base nos estudos da PTF e de seus principais indicadores, chegou-se às projeções de 2 cenários econômicos. O cenário inferior conta com um crescimento médio de 1,4% a.a., enquanto o cenário econômico superior apresenta uma taxa média de 2,2% a.a, conforme mostra a Figura 2.




Figura 2. Evolução do consumo energético por cenário econômico. Fonte: Ministério de Minas e Energia: Cenários de Demanda para o PNE 2050 (2018).

A Figura 2 revela que os primeiros 15 anos possuem aumento mais expressivo na demanda por energia. Inclusive, o consumo no cenário superior (562 Mtep) será maior que o dobro em relação ao ano base (261 Mtep). Percebe-se ainda que nos 15 primeiros anos o consumo energético crescerá de forma mais acelerada. Isso pode ser explicado com base na maior expansão da atividade industrial e da

produção de petróleo e gás natural que ocorrerá nesse mesmo período. Após esses 15 anos, espera-se que as políticas e os investimentos na área de energia gerem resultados, aumentando a eficiência da utilização de energia. Sendo assim, a maior eficiência energética desacelerará o consumo. A fim de atender essa demanda, o Brasil possui diversos recursos energéticos em que os principais são o petróleo e seus derivados, a eletricidade e os produtos da cana-de-açúcar (bagaço e etanol). Ainda que haja grande apelo internacional para a criação de matrizes energéticas "descarbonizadas", a matriz brasileira continuará dependente do petróleo e de seus derivados, conforme mostra a Figura 3.




Figura 3. Projeções da participação das fontes energéticas no consumo final de energia entre 2015 e 2050 para os cenários inferior e superior do crescimento econômico. Fonte: Ministério de Minas e Energia: Cenários de Demanda para o PNE 2050 (2018).

Apesar da matriz energética brasileira contar com grande participação dos derivados de petróleo até 2050, tanto para o cenário inferior quanto o superior, percebe-se pela Figura 3, uma redução na sua contribuição e um aumento na participação da eletricidade, que apesar de ser utilizada em todos os setores produtivos, será mais impactada pelo residencial.

A Figura 4 apresenta o consumo final de energia por cada setor produtivo do Brasil de 2015 a 2050.




Figura 4. Evolução do consumo energético por setor produtivo. Fonte: Ministério de Minas e Energia: Cenários de Demanda para o PNE 2050 (2018).

A partir da Figura 4 fica claro que o setor industrial e de transportes são os maiores consumidores de energia no Brasil, consumindo juntos, mais de 50% do total anual. A Figura 5 especifica a participação de cada fonte energética no consumo de energia do setor industrial brasileiro, que é o maior consumidor do país.




Figura 5. Participação das fontes energéticas no consumo final do setor industrial. Fonte: Ministério de Minas e Energia: Cenários de Demanda para o PNE 2050 (2018).

Analisando a Figura 5, percebe-se um leve crescimento na participação da eletricidade e do gás natural, havendo redução no consumo de carvão e derivados. Além disso, os produtos derivados da cana-de-açúcar possuem aumento no cenário inferior e redução no cenário superior. As informações das Figuras 4 e 5 dão ao Estado uma ideia sobre os principais setores consumidores de energia e quais são as fontes energéticas mais requisitadas. Dessa forma, fica mais fácil identificar os setores e recursos que precisam de mais atenção, políticas e investimentos em tecnologias e combustíveis sustentáveis. Isso é de fundamental importância para atender a demanda energética do país ao mesmo tempo em que se busca uma mudança significativa na matriz energética brasileira em longo prazo.

No Acordo de Paris em 2015, o Brasil se comprometeu a reduzir suas emissões de gás carbônico em 37% até 2025 e 43% até 2030, com base nas emissões de 2005. Isso requer todo um planejamento energético para produzir a energia necessária ao país, visando uma menor emissão de gás carbônico. É notório que um prazo tão longo quanto o do PNE 2050 apresenta inúmeras incertezas e desafios na projeção da demanda energética. Essas instabilidades incluem a competitividade dos recursos energéticos, as políticas e relações internacionais, crises ambientais e

econômicas, dentre tantas outras. Todavia, os estudos e análises do PNE 2050 são necessários não somente para garantir o abastecimento de energia do país, mas também para identificar os setores mais consumistas e os recursos energéticos mais nobres e disponíveis nas reservas brasileiras. Portanto, estudos técnicos bem-feitos e aliados à boa vontade do Estado brasileiro são imprescindíveis para o aumento da eficiência energética e da utilização de recursos sustentáveis de menor impacto ambiental.

Sabe-se que as emissões de dióxido de carbono são favorecidas, principalmente, pelo aumento da queima dos combustíveis fósseis. A partir da Figura 3, percebemos que esses combustíveis (petróleo e derivados, carvão mineral e gás natural) possuirão grande participação no abastecimento de energia do Brasil até 2050. Sendo assim, o crescimento econômico brasileiro previsto entre 2015 e 2050 impulsionará a queima dos combustíveis fósseis para atender o aumento da demanda energética nesse mesmo período. Se o Brasil não investir de forma efetiva em uma maior diversidade na sua matriz energética, diminuindo a contribuição dos combustíveis fósseis, a tendência será de aumentar as emissões de dióxido de carbono, não atendendo as metas de redução prometidas no Acordo de Paris. Entretanto, a substituição dos combustíveis fósseis por outras fontes ou tecnologias não é tão simples, já que envolve não só os custos dessas, mas também a eficiência, disponibilidade natural e reestruturação do setor energético brasileiro. Além disso, é difícil identificar quais dessas fontes e tecnologias não fósseis possuem maior impacto na redução das emissões de dióxido de carbono, além do fato de que há outras variáveis envolvidas no crescimento econômico do país, no consumo energético, e por fim, nas emissões de dióxido de carbono. Alguns exemplos são o crescimento populacional, a variação da temperatura média e do índice pluviométrico (exigindo maior uso de aquecedores ou ar-condicionados, além de maior ou menor irrigação para o agronegócio), além da participação no consumo final de energia de cada fonte energética. Portanto, não há uma clara relação entre as emissões de dióxido de carbono e as inúmeras variáveis únicas de cada país, exigindo assim, modelos matemáticos mais complexos que sejam eficientes na resolução dessas questões.

Como ficou claro no Acordo de Paris, a única forma das reduções de dióxido de carbono terem um efeito significativo no controle da temperatura global é se cada país se esforçar a reduzir suas próprias emissões. Para se alcançar esse objetivo é imprescindível um modelo matemático, com precisão aceitável, que avalie a emissão de gás carbônico em cada nação em relação a outras variáveis particulares de cada país. Identificando a importância que cada variável estudada possui nas emissões de dióxido de carbono é possível propor novas políticas e investimentos, com base nos recursos naturais de cada país, a fim de favorecer ou inibir esses indicadores, reduzindo as emissões de gás carbônico. Dentre as inúmeras metodologias para a resolução de sistemas não lineares há a utilização das Redes Neurais Artificiais (BUDUMA; LOCASCIO, 2017).

2.17. REDES NEURAS ARTIFICIAIS

2.17.1. As máquinas inteligentes e suas limitações

Há inúmeros sistemas de computadores capazes de realizar as mais diversas tarefas, e a partir da história percebe-se que a força motriz do seu desenvolvimento foram problemas específicos e bem definidos (ANDERSON, 1995). Todavia, com o rápido desenvolvimento dos hardwares e a necessidade de solucionar problemas cada vez mais complexos e generalistas, houve a necessidade do desenvolvimento de sistemas mais inteligentes (ANDERSON, 1995). O cérebro humano é o sistema mais inteligente conhecido até então, recebendo e processando inúmeras informações captadas pelos sentidos em tempo real (MLODINOW, 2013). Isso permite ao ser humano experimentar diversos sentimentos, sonhar, armazenar memórias, dentre outras atividades, permitindo a resolução de problemas que são impossíveis aos computadores mais modernos (BUDUMA; LOCASCIO, 2017). Após alguns meses do seu nascimento, um bebê já é capaz de distinguir vozes, reconhecer os pais, diferenciar objetos, enquanto que na infância o cérebro, pesando apenas 1 kg, já é capaz de rastrear objetos, associar diversos sons e desenvolver uma sofisticada compreensão da gramática (DAMON et al., 2006).

Com base nas incríveis funções desempenhadas pelo cérebro humano, há um enorme desejo de se construir máquinas que possam realizar tarefas básicas da sociedade, como dirigir, faxinar, dentre outras. Entretanto, a construção dessas

máquinas altamente inteligentes não é uma tarefa fácil e exige a resolução de problemas computacionais complexos que pode ser feita em microssegundos pelo cérebro humano. Sendo assim, para vencer os desafios computacionais é necessária uma mudança radical na forma de programação atual (BUDUMA; LOCASCIO, 2017). Apesar da alta capacidade dos computadores modernos, a essência de seus programas foi desenvolvida para fazer 2 tarefas com alto desempenho, sendo elas as operações aritméticas e a execução de uma lista de funções (BUDUMA; LOCASCIO, 2017). Caso o problema estudado seja ligeiramente diferente, como o reconhecimento de padrões, de objetos, categorização de dados, dentre outros, as máquinas atuais terão maiores dificuldades, o que leva a necessidade de uma abordagem computacional diferente dos sistemas tradicionais (BUDUMA; LOCASCIO, 2017).

2.17.2. Redes Neurais Artificiais e o modelo de neurônio artificial

As Redes Neurais Artificiais (RNAs) são modelos computacionais que se baseiam na estrutura e interconexão presentes nos neurônios biológicos (HAYKIN, 1999). Elas são formadas por unidades de processamento interconectadas que armazenam o conhecimento, adaptando-se e aprendendo a partir de treinamentos para identificar padrões (GURNEY, 1997). As RNAs tem a capacidade de resolver, com qualidade, inúmeros problemas que envolvem sistemas não lineares, análise de dados, modelagem, simulação, reconhecimento de padrões, dentre outros, e fornecem os melhores resultados em relação aos sistemas tradicionais (DOZIC; UROSEVIC, 2019; FAYED et al., 2019; POZNYAK; CHAIREZ; POZNYAK, 2019). O cérebro humano possui como base o neurônio biológico, que é otimizado para receber e processar informações, passando adiante os seus resultados a um outro neurônio. Ao receber as informações, o neurônio biológico fortalece ou enfraquece suas conexões com as informações recebidas, de acordo com a frequência em que elas são utilizadas, tornando-se capaz de "aprender" e de determinar a importância que cada informação possuirá no seu resultado que será transmitido à próxima célula (BUDUMA; LOCASCIO, 2017; RESTAK, 2001). Essa forma de aprendizagem do neurônio biológico foi transformada em uma linguagem lógica de programação em 1943 por Warren S. McCulloch e Walter H. Pitts, representada na Figura 6.




Figura 6. Esquema de um neurônio artificial.

Fonte: Buduma (2017).

Pela Figura 6, interpreta-se que as variáveis de entrada estudadas são representadas por $X_1, X_2 \dots X_n$ e multiplicadas por pesos específicos ($W_1, W_2 \dots W_n$), criando, dessa forma, a lógica do neurônio artificial (z), conforme a Equação 1 (BUDUMA; LOCASCIO, 2017).

$$z = \sum_{i=0}^n W_i X_i \quad (1)$$

A lógica do neurônio passa por uma função f para que a saída do neurônio, y , seja calculada, conforme Equação 2,

$$Y = f(z + b)$$

(2)

podendo ou não haver o termo b , que é uma constante chamada bias, utilizada para melhorar o ajuste do modelo (ANDERSON, 1995; BUDUMA; LOCASCIO, 2017; HAYKIN, 1999; GURNEY, 1997). Em se tratando de linguagem de programação, tanto as variáveis de entradas quanto os seus respectivos pesos podem ser interpretados como vetores. Dessa forma, a saída do neurônio é dada a partir do somatório da multiplicação entre esses dois vetores, com ou sem a inclusão do termo bias, que passará por uma função de transformação f . Sendo assim, os neurônios artificiais são, na verdade, uma série de manipulações vetoriais que podem ser implementados em softwares de programação (ANDERSON, 1995; BUDUMA; LOCASCIO, 2017; HAYKIN, 1999).

2.17.3 Arquiteturas das Redes Neurais Artificiais

Ainda que um neurônio biológico seja mais poderoso do que um neurônio artificial, é impossível que ele resolva sozinho problemas muito complexos (BUDUMA; LOCASCIO, 2017). Sendo assim, o cérebro humano utiliza diversos neurônios dispostos em camadas, sendo que o córtex humano (responsável por grande parte da inteligência) é organizado em 6 camadas (MOUNTCASTLE, 1957; VELEZ-FORT et al., 2018). Com uma estrutura dessas, as entradas (sensoriais) passam de uma camada à outra, através dos neurônios até que seja formada uma compreensão conceitual (BUDUMA; LOCASCIO, 2017). Dessa forma, o cérebro humano pode identificar se está olhando para um gato, um elefante, distinguir diversos cheiros, dentre outras funções. Compreendendo esses conceitos, a Figura 7 mostra uma Rede Neural Artificial simplificada.




Figura 7. Representação simplificada de uma Rede Neural Artificial de 3 camadas. Fonte: Buduma (2017).

A partir da Figura 7, pode-se identificar que a camada inferior recebe três variáveis de entrada e a camada do topo computa a resposta final do problema estudado. A camada intermediária é chamada de “camada oculta”, que é o termo utilizado para as camadas que não sejam a de entrada e a de saída. É nas camadas ocultas que a RNA se concentra na resolução dos problemas, automatizando a identificação de padrões e quaisquer outros recursos úteis a partir das entradas fornecidas na primeira camada. O termo $w^{(k)}_{ij}$ é o peso da conexão entre o i^o neurônio na k^a camada e o j^o neurônio na $k+1$ camada. Sendo assim, a resolução de problemas a

partir das RNAs depende da obtenção adequada dos valores desses pesos (BUDUMA; LOCASCIO, 2017; MENET et al., 2020). Percebe-se, também, pela Figura 7, que os neurônios de uma mesma camada não se comunicam entre si, e que as informações avançam de uma camada inferior para uma camada superior, não havendo fluxo de informação no sentido contrário. Essa estrutura de funcionamento é chamada de rede *Feed Forward*, em que a alimentação da rede avança através dos neurônios artificiais em apenas um sentido (BUDUMA; LOCASCIO, 2017; STOFFEL et al., 2020). Apesar da RNA apresentada na Figura 7 possuir 3 camadas e 3 neurônios em cada uma, isso é pouco visto em RNAs práticas. Geralmente, as camadas ocultas possuem menos neurônios que as demais e isso é feito para forçar a aprendizagem da rede com compactações dos dados iniciais. Um neurônio artificial não precisa estar conectado com todos os outros da próxima camada. Saber quais neurônios estarão conectados dependerá de cada problema e será aprendido com a prática. Em relação às entradas e saídas, é preciso compreendê-las como representações vetorizadas. Em analogia às imagens, é como se as entradas fossem pixels (representações vetorizadas) e, a saída, a imagem propriamente dita (um vetor). Sendo assim, uma RNA com 2 neurônios em sua camada de saída daria uma resposta do tipo [1,0] se a imagem for um cachorro, [0,1] se for um gato, [1,1] se possuir os dois animais e [0,0] se não for nenhum dos dois (BUDUMA; LOCASCIO, 2017).

Conhecendo os princípios básicos de um neurônio e de uma RNA, pode-se representá-la como uma série de vetores e operações matriciais. Basta representar as entradas como um vetor $X = [X_1, X_2, \dots, X_n]$ e a resposta ao problema estudado como um vetor $Y = [Y_1, Y_2, \dots, Y_m]$, encontrada a partir da propagação de informações através dos neurônios artificiais. Sendo assim, a resposta pode ser encontrada por uma multiplicação matricial, em que o peso das entradas é uma matriz $W_{n \times m}$ e a constante bias um vetor de tamanho m . Dessa forma, a resposta é dada a partir da aplicação da função de transformação elemento a elemento do vetor, conforme a Equação 3 (BUDUMA; LOCASCIO, 2017).

$$Y = f(W^t X + b) \quad (3)$$

Ainda que as RNAs apresentem diversas vantagens na resolução de problemas complexos, os neurônios artificiais possuem uma função de transformação f que se não for bem escolhida trará inúmeras limitações à resolução dos complexos problemas não lineares.

2.17.4. Limitações dos neurônios artificiais lineares e a introdução da não linearidade nas funções de transformação

Para compreender as limitações de um neurônio artificial linear é necessário considerar uma RNA, cujos neurônios usem a função linear apresentada na Equação 4

$$f(z) = az + c \quad (4)$$

Nesse caso, se o neurônio artificial desejar estimar o preço final de um lanche em uma hamburgueria, basta considerar $a = 1$ e $c = 0$. Dessa forma, a lógica do neurônio será o próprio termo z em que serão consideradas três variáveis de entrada (hambúrguer, refrigerante e batata frita) de forma que o preço final do lanche será definido pelo somatório da multiplicação de cada entrada com seu respectivo preço (peso), conforme a Figura 8.




Figura 8. Representação de um neurônio artificial linear calculando o preço final de um lanche em uma hamburgueria. Fonte: Adaptado de Buduma (2017).

No problema ilustrado pela Figura 8, a relação entre o preço final do lanche e os seus produtos individuais (hambúrguer, batata e refrigerante), bem como seus respectivos preços (pesos) é muito clara e linear. Sendo assim, o neurônio artificial linear na arquitetura *Feed Forward* (sem a presença de camadas ocultas), em que só há fluxo de informação em uma única direção, funciona muito bem (BUDUMA; LOCASCIO, 2017). Entretanto, em uma situação mais complexa e não linear, por exemplo, a relação entre as emissões de dióxido de carbono e indicadores como a população do país, a temperatura média anual, queimadas em florestas e a participação dos recursos energéticos no consumo final de energia, não se conhece a influência de cada uma dessas variáveis na emissão final de dióxido de carbono. Além disso, ainda que conhecêssemos o efeito que o aumento ou a diminuição de uma determinada variável terá sobre a emissão de dióxido de carbono, não saberíamos de forma precisa o peso dessa variável, isso é, a magnitude de sua influência nas emissões. Em uma situação complexa como essa, fica nítido como um neurônio linear e uma arquitetura do tipo *Feed Forward* não conseguem resolver de forma satisfatória problemas complexos. Inclusive, foi discutido na sessão 1.7.3, que é nas camadas ocultas da RNA (não apresentadas na Figura 8) que ocorre o processo de aprendizagem e automatização do processo de reconhecimento de padrões de uma RNA. Além disso, a estrutura *Feed Forward*, por possuir apenas uma direção ao fluxo de informações, não consegue "refletir" sobre o erro encontrado em sua resposta, e com isso, ajustar os pesos de cada variável de entrada (que em problemas complexos e não lineares são, geralmente, desconhecidos). Portanto, há uma necessidade em se inserir algum tipo de não linearidade à função $f(z)$ do neurônio artificial para que ele encontre respostas satisfatórias aos problemas não lineares (BUDUMA; LOCASCIO, 2017; PANEIRO; RAFAEL, 2020).

Há três exemplos principais em relação aos neurônios que utilizam em suas resoluções a não linearidade, sendo eles:

- 1) o neurônio sigmoidal;
- 2) o neurônio *tahn*;
- 3) o neurônio ReLU (*Restricted Linear Unit*)

O neurônio sigmoidal utiliza a Equação 5 como função de ativação:

$$f(z) = \frac{1}{1 + e^{-z}} \quad (5)$$

Essa equação pode ser mais bem compreendida a partir da análise gráfica, conforme a Figura 9.




Figura 9. Representação gráfica da saída de um neurônio artificial sigmoidal.

Fonte: Buduma (2017).

A partir da Figura 9 percebe-se que quando a lógica do neurônio z é muito pequena, a sua saída aproxima-se de 0. Do contrário, a saída do neurônio alcança o valor de 1 para lógicas maiores. O neurônio *tahn* utiliza a função hiperbólica tangencial na lógica do neurônio, de acordo com a Equação 6.

$$f(z) = \tanh(z) \quad (6)$$

A Figura 10 representa, graficamente, a saída do neurônio *tahn* em função da lógica do neurônio.




Figura 10. Representação gráfica da saída de um neurônio artificial *tahn*. Fonte: Buduma (2017).

Observando a Figura 10, percebe-se que apesar de possuir o mesmo formato em "S" apresentado pela função sigmoide, a saída da função *tahn* está limitada entre -1 e +1, sendo centrada no valor 0. Essa maior amplitude de saída a torna uma das mais utilizadas nos neurônios artificiais não lineares (BUDUMA; LOCASCIO, 2017; MUNA

SINGHE et al., 2019). Uma terceira forma de se adicionar a não linearidade a um neurônio artificial é a partir da ReLU (*Restricted Linear Unit*). Ela utiliza uma função de ativação conforme a Equação 7.

$$f(z) = \max(0, z) \quad (7)$$

A Equação 7 é conhecida como um “taco de hóquei” (*hockey-stick-shaped*), devido ao seu formato, conforme a Figura 11.




Figura 11. Representação gráfica da saída de um neurônio artificial *ReLU*. Fonte: Adaptado de Buduma (2017).

A função *ReLU*, apresentada na Figura 11, assim como a sigmoideal e a *tanh*, é bastante utilizada para adicionar a não linearidade aos neurônios artificiais (BUDUMA; LOCASCIO, 2017; NAIR; HINTON, 2010; PIRMORADI et al., 2020).

Com a inclusão das funções não lineares, os neurônios artificiais adquirem a capacidade de resolver problemas mais complexos. Além disso, há situações em que a resposta desejada é na verdade uma distribuição de probabilidades e não um vetor mutuamente exclusivo (BUDUMA; LOCASCIO, 2017; LECUN et al., 1998). Sendo assim, para a distinção entre números escritos à mão, como os da Figura 12, a resposta da RNA escolhe um dígito excluindo todos os outros.



Figura 12. Dígitos manuscritos para serem reconhecidos por uma RNA. Fonte: Lecun et al. (1998).

Todavia, números como (0,6) ou (3,8), a depender da escrita podem ser facilmente confundidos, impossibilitando o seu reconhecimento de forma precisa. Sendo assim, utilizar uma densidade probabilística transmite uma noção melhor sobre o resultado. Para tal, a saída da RNA deve ser um vetor com o formato $[P_0 \ P_1 \ P_2 \ \dots \ P_9]$, de modo que o somatório (normalizado) de $[P_0 + \dots + P_9]$ seja igual a 1. Essa estrutura necessita do somatório da saída de cada neurônio artificial na camada final e é conhecida como *softmax layer* (BUDUMA; LOCASCIO, 2017). Nessa estrutura, uma boa predição seria aquela em que o termo P_2 , por exemplo, fosse próximo de 1, enquanto os outros fossem próximos de 0, indicando que o dígito analisado se trata do número 2. Uma predição fraca seria aquela em que os termos do vetor de saída $[P_0 + \dots + P_9]$ tenham valores próximos entre si.

2.17.5. O treinamento das Redes Neurais Artificiais e o algoritmo de Retropropagação (*Back Propagation*)

A utilização das Redes Neurais Artificiais para a resolução de problemas complexos resume-se a encontrar os pesos mais adequados a cada uma das variáveis de entrada (BUDUMA; LOCASCIO, 2017; GOODFELLOW; BENGIO; COURVILLE, 2016). Esse objetivo pode ser alcançado a partir de um treinamento supervisionado ou de um treinamento não-supervisionado (RAUBER, 2005). Na aprendizagem supervisionada apresenta-se à rede alguns exemplos (de entradas com a resposta correspondente) para que interativamente os pesos das variáveis de entrada sejam modificados de forma a minimizar os erros em relação ao banco de dados utilizado no treinamento (BUDUMA; LOCASCIO, 2017; ROJAS-DELGADO; TRUJILLO-RASUA; BELLO, 2019). A regressão linear é um exemplo de treinamento supervisionado. Isso porque a partir de um conjunto de dados (entradas e saídas correspondentes) busca-se uma equação cujos coeficientes lineares e angular minimizem a diferença média entre os valores reais e os preditos pelo modelo encontrado (RAUBER, 2005). O treinamento não-supervisionado refere-se à situação em que apenas as variáveis de entrada são conhecidas. Dessa forma, a rede não possui nenhuma informação de saída para realizar comparações iterativas, de modo a obter um modelo que minimize os erros entre as saídas reais e as preditas (RAUBER, 2005). Esse treinamento é normalmente utilizado para a determinação de categorias e comportamentos estatísticos relevantes que ainda não são conhecidos, fazendo com que a rede elabore suas próprias representações para as entradas disponíveis (RAUBER, 2005). O treinamento não-supervisionado das RNAs tem contribuído de forma significativa para o reconhecimento de padrões e para a categorização de dados visuais, ou seja, entradas com formato de imagens (REMPEL; SILVA, 2001).

Após uma quantidade suficiente de dados, espera-se que a rede consiga computar a solução do problema a partir de novas entradas com um erro aceitável. Essa metodologia parece simples, ao passo em que se poderia utilizar um sistema de equações para encontrar os pesos das variáveis de forma que o erro da resposta em relação a resposta real seja próximo de 0. Essa situação é válida para neurônios lineares, que não seriam adequados a problemas complexos e não lineares como o da relação entre as emissões do dióxido de carbono e alguns indicadores (participação de fontes energéticas na matriz de consumo final, temperatura média

anual, etc). Uma vez que se utilize funções de transformação não lineares aos neurônios, não é mais possível montar um sistema de equações para a obtenção dos pesos, sendo necessário uma nova estratégia de treinamento (BUDUMA; LOCASCIO, 2017).

O algoritmo de Retro Propagação (*Back Propagation*) foi desenvolvido por Rumelhart, Geoffrey e Ronald em 1986 (BUDUMA; LOCASCIO, 2017; RUMELHART; HINTON; WILLIAMS, 1988). Esse algoritmo é uma das inúmeras estratégias de treinamento utilizadas para que a RNA aprenda os padrões e as relações envolvidas no problema estudado de modo a computar respostas adequadas (BUDUMA; LOCASCIO, 2017; AMIN, 2020). Com essa estratégia, não nos focamos na ação de cada neurônio. O que observamos é a velocidade das alterações que ocorrem na saída da rede a partir das mudanças realizadas nas camadas ocultas (BUDUMA; LOCASCIO, 2017). Sendo assim, é possível observar as alterações no próprio erro da resposta computada pela RNA e aplicar diversos efeitos individuais nas unidades ocultas para obtermos os erros aceitáveis (BUDUMA; LOCASCIO, 2017). De maneira simplista, o algoritmo de Propagação Retrógrada analisa o problema estudado em duas situações (BUDUMA; LOCASCIO, 2017; BAO et al., 2019; WANG et al., 2020). A primeira é o sentido tradicional do fluxo de informações que vai da camada de entrada até a camada final da RNA. Nesse caso, os pesos de cada variável são fixados e a RNA computa uma resposta que ao ser comparada à resposta verdadeira gera um erro. Na segunda situação, a RNA propaga o sinal desse erro da camada de resposta em direção às camadas inferiores de modo que cada neurônio receba apenas uma parte desse sinal que é proporcional à sua contribuição no erro total. Esse procedimento permite que os pesos em cada neurônio sejam ajustados para que uma nova resposta, e consequentemente, um novo erro sejam computados. Essa metodologia iterativa permite que os pesos sejam ajustados até que o erro da resposta computada seja tão pequeno quanto se queira (MATSUNAGA, 2012). A Figura 13 apresenta uma RNA utilizando o algoritmo de Retro Propagação.

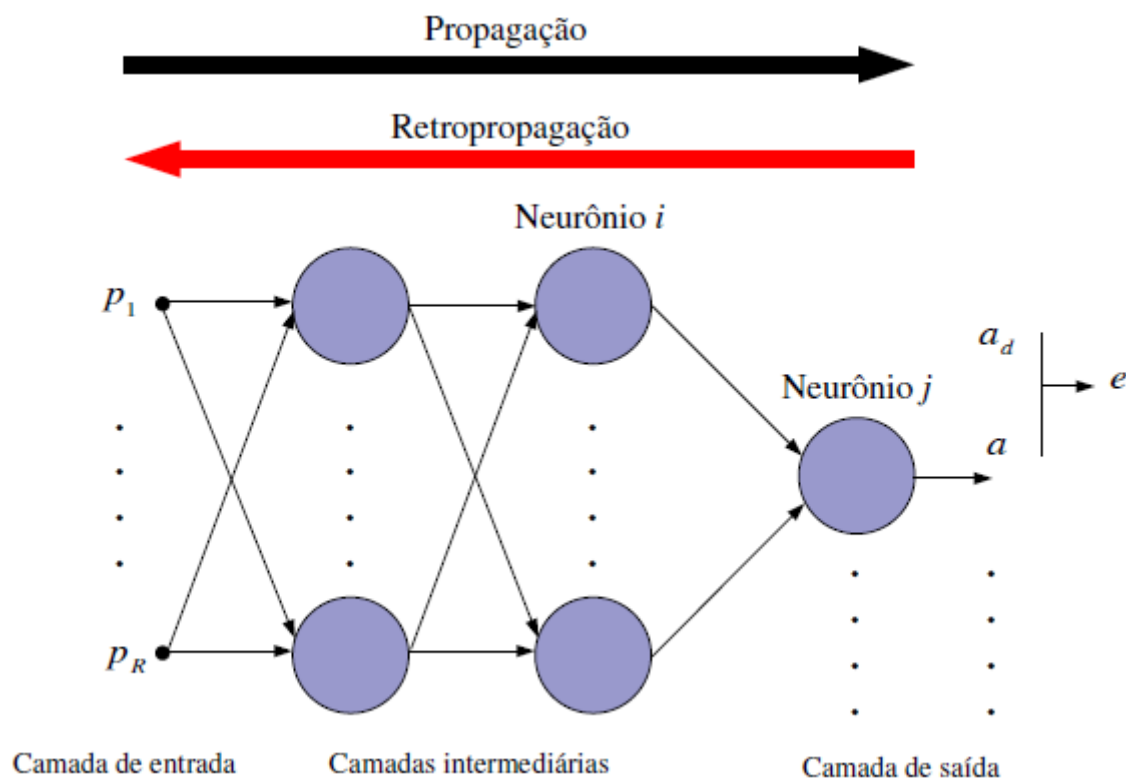


Figura 13. Rede Neural Artificial utilizando o algoritmo de Retro Propagação que permite o fluxo de informações em 2 sentidos através da arquitetura da rede. Fonte: Matsunaga (2012).

Pela Figura 13, fica claro que a informação pode fluir da camada de entrada para a camada de saída e vice-versa. O termo a representa a saída computada pela RNA, que é constantemente comparada ao termo a_d , que representa a resposta real ao problema para os dados de entrada utilizados no treinamento. Desse modo, o procedimento de treinamento da RNA a partir do algoritmo de Retro Propagação é focado em se ajustar o peso de cada unidade da rede para se obter respostas adequadas.

Conhecendo-se o conceito das Redes Neurais Artificiais, o seu elemento principal (o neurônio artificial), e aplicando a ele a não linearidade, é possível resolver problemas complexos e não lineares como a relação entre as emissões de dióxido de carbono de um país e seus indicadores únicos (recursos energéticos, PIB, população, temperatura média anual, dentre outros). Devido às vantagens oferecidas pelas RNAs, estudos vem utilizando essa ferramenta para estudar problemas complexos e não lineares no setor energético de diversos países a fim de apresentar sugestões

políticas e estratégicas que permitam o desenvolvimento econômico aliado à responsabilidade socioambiental (DOZIC; UROSEVIC, 2019; MASON; DUGGAN; HOWLEY, 2018; XU; SCHWARZ; YANG, 2019; SANGEETHA; AMUDHA, 2018; YU et al., 2019; KHASHMAN; KHASHMAN; MAMMADLI, 2016; TAGHAVIFAR et al., 2016; HEYDARI et al., 2019; CAPIZZI et al., 2015; PINO-MEJIAS et al., 2017).

2.17.6 A utilização das Redes Neurais Artificiais em problemas do setor energético

As altas emissões de dióxido de carbono e de outros poluentes atmosféricos representam um risco à saúde humana e ao equilíbrio do planeta. Desse modo, é necessário o desenvolvimento de modelos que possam prever essas emissões e correlacioná-las aos indicadores energéticos, sócio-econômicos e ambientais de um determinado país. Entretanto, encontrar essas correlações para se propor meios que reduzam essas emissões não é uma tarefa fácil. Isso porque, essas correlações não são lineares, mas complexas, dificultando uma previsão de qualidade a partir de modelos matemáticos tradicionais. Sendo assim, as Redes Neurais Artificiais ao utilizarem funções não lineares, vem se destacando na resolução de problemas do setor energético. Nessa área, as Redes Neurais Artificiais encontram de modo satisfatório as complexas relações entre as emissões de poluentes e diversos indicadores energéticos. A partir disso, é possível propor mudanças eficazes que diminuam as emissões de dióxido de carbono e de outros gases poluentes, a fim de se contribuir com a preservação ambiental. Nos próximos parágrafos, serão apresentados alguns estudos que utilizaram as Redes Neurais Artificiais para prever as emissões de poluentes atmosféricos e identificar os indicadores que podem ser alterados para diminuir essas emissões.

Dozic e Urosevic (2019) analisaram e apresentaram um modelo para o sistema de energia da União Europeia. Os autores fizeram previsões para as emissões de dióxido de carbono até 2050, levando em consideração o Planejamento Energético da União Europeia e 10 indicadores (PIB, população, temperatura média anual, consumo de energia elétrica, fornecimento total de energia, % de fontes renováveis, de energia nuclear, de petróleo, de gás natural e de combustíveis fósseis no fornecimento total de energia). Os autores utilizaram uma RNA de múltiplas

camadas e com o algoritmo de Retropropagação, além da função não linear *tahn* nos neurônios artificiais. Foram utilizados os dados de 1990-2015 para o treinamento da RNA que aprendeu o comportamento do sistema estudado com acurácia aceitável. Em seguida, os 10 indicadores utilizados foram extrapolados com base em uma regressão linear e esses valores alimentaram a RNA para que ela fornecesse a emissão de dióxido de carbono. A partir dos dados históricos da União Europeia e das suas políticas para o setor energético, os autores do trabalho concluíram que as emissões de dióxido de carbono serão reduzidas em cerca de 67,72% no ano de 2050 em relação a 1990. Nesse estudo, o modelo encontrado obteve erro menor de 2%, o que demonstra a qualidade do modelo frente a um problema complexo e não linear. Aqui, percebemos a relevância das Redes Neurais Artificiais em problemas complexos que envolvem emissões de dióxido de carbono, indicadores energéticos e socioeconômicos de um país. Para a União Europeia, as emissões foram previstas com boa acuidade, permitindo concluir que a região caminha para o cumprimento do Acordo de Paris. Caso os resultados do estudo demonstrassem o contrário, seria possível realizar maiores investigações com o intuito de propor soluções de modo que o Acordo de Paris fosse cumprido.

Xu et al. (2019) utilizaram uma RNA para determinar o ano de pico das emissões de dióxido de carbono pela China, que é o maior emissor mundial, analisando para isso, os cenários de desenvolvimento econômico do país. Os autores utilizaram uma RNA dinâmica e não linear. Os indicadores do modelo foram o PIB, a população, a % da população urbana, a % dos setores secundários e terciários na economia da China, o total de energia consumida, a % dos combustíveis fósseis no consumo de energia e os investimentos do governo no setor energético. Os indicadores foram baseados em 3 cenários de desenvolvimento econômico (baixo, médio e alto) e para cada um, os autores encontraram os anos de pico nas emissões de dióxido de carbono (bilhões de toneladas) que foram 2029 (10,08), 2031 (10,78) e 2035 (11,63), respectivamente. Os autores também estimaram o nível de relevância de cada indicador na emissão de dióxido de carbono e perceberam que tanto os setores industriais, por seu alto consumo de carvão, quanto os investimentos do governo possuem grande impacto nessas emissões. Sendo assim, os autores sugerem que o país siga um cenário econômico moderado e que o governo invista em novas

tecnologias energéticas para a redução do consumo de carvão no setor industrial. Sendo assim, fica claro que o alto consumo de fontes energéticas fósseis possui grande impacto nas emissões de dióxido de carbono. Entretanto, o estudo também revelou a importância que as ações governamentais possuem nessas emissões. Sendo assim, um desafio dos governos federais é o de encontrar soluções no setor energético que diminuam a emissão de poluentes sem, no entanto, prejudicar o desenvolvimento do país.

Heydari et al. (2019) avaliaram a tendência das emissões de dióxido de carbono no Irã, no Canadá e na Itália, relacionando as emissões com o consumo de fontes energéticas, como o petróleo, o carvão, o gás natural e as renováveis. O estudo utilizou uma RNA com o algoritmo *Grey Wolf Optimization*. Os dados sobre o consumo dos recursos energéticos abrangeram os anos de 1980-2015. A análise dos resultados mostrou que a RNA foi capaz de prever as emissões de dióxido de carbono de forma acurada com erro médio quadrático inferior a 0,02. Sendo assim, os autores concluíram que o modelo utilizado é adequado para previsões a longo prazo das emissões de dióxido de carbono a partir dos cinco indicadores analisados. Mais uma vez, o uso das Redes Neurais Artificiais foi eficaz na previsão das emissões de dióxido de carbono a partir do consumo de diversas fontes energéticas. Portanto, é possível enxergar que a mudança na matriz energética de um país é uma das soluções para se reduzir as emissões de dióxido de carbono, sem que seu desenvolvimento seja prejudicado.

Sangeetha e Amudha (2018) estudaram as emissões de dióxido de carbono na Índia, prevendo-as com base no consumo de energia primária e dos diferentes recursos energéticos, como o carvão mineral, o gás natural e o petróleo. O estudo estimou os indicadores para o período de 2017-2030 a partir de um modelo de Regressão Linear Múltipla *Multiple Linear Regression* e de um modelo não linear com base no algoritmo de Otimização de Enxame de Partículas *Particle Swarm Optimization*. Os resultados mostraram maior acurácia no modelo não linear, cujos resultados alimentaram uma RNA para que as emissões de dióxido de carbono na Índia fossem previstas entre 2017-2030. A RNA utilizada contou com o algoritmo de Retropropagação e previu um grande aumento das emissões no período analisado.

Portanto, para que a emissão de dióxido de carbono seja reduzida na Índia, os autores concluíram que há a necessidade de estudos que incluam novos indicadores. Isso deve ser feito para que as causas do aumento expressivo nas emissões sejam melhor identificadas, possibilitando sugestões nas políticas e estratégias energéticas da Índia. A partir desse estudo, é possível perceber a superioridade que um modelo não linear possui frente a um modelo linear. Além disso, a pesquisa alertou a necessidade de se incluir novos indicadores ao modelo, além do consumo energético por fontes de energia. Pois assim, será possível compreender melhor os fatores que intensificam as emissões de dióxido de carbono e auxiliar de forma eficaz as políticas energéticas da Índia.

Mason et al. (2018) modelaram uma RNA com um algoritmo de otimização evolutiva para prever, a curto prazo, a demanda de energia, a geração de energia eólica e a emissão de dióxido de carbono na Irlanda. Os autores utilizaram dados históricos de 1 mês para o treinamento da rede e 1 mês para os testes. Com base nos resultados, a RNA foi capaz de prever com acurácia as três respostas estudadas. Além disso, os autores concluíram que ao alimentar a RNA com dados que fogem do padrão dos dados utilizados no treinamento da RNA, encontra-se erros maiores. Entretanto, de modo geral, a RNA apresentou previsões de boa acurácia.

Yu et al. (2018) modelaram as correlações entre as emissões de dióxido de carbono e a estrutura natural (composição elemental) de alguns combustíveis em uma caldeira. Os autores usaram uma Rede Neural Artificial com o algoritmo de Retropropagação, que foi acoplado ao Algoritmo Genético (*Genetic Algorithm*) para facilitar o aprendizado da RNA e encontrar as complexas relações não lineares entre as emissões de dióxido de carbono e as quantidades dos elementos presentes (C, H e O) em cada combustível. A partir dos dados obtidos com a queima dos combustíveis utilizados, a RNA usada conseguiu prever a emissão de dióxido de carbono a partir da estrutura elemental deles. Sendo assim, os autores encontraram um modelo matemático que a partir da composição química do combustível, prevê de forma acurada a emissão de dióxido de carbono em sua queima. De acordo com os autores, esse resultado permite sugerir e otimizar novas estruturas para os combustíveis futuros, de modo que sua queima emita menores quantidades de

dióxido de carbono. Sendo assim, o desafio atual por parte dos governos é o de investir no presente, em combustíveis mais limpos, para que no futuro, atinjam o desenvolvimento sustentável.

Pino-Mejías et al. (2016) modelaram e compararam uma regressão linear com uma RNA em relação às suas acurácias na predição da demanda e do consumo energético em prédios comerciais no Chile. Os autores avaliaram, também, as emissões de dióxido de carbono, provenientes da energia consumida em sistemas de aquecimento/refrigeração desses edifícios. Foram utilizados oito indicadores a respeito da estrutura dos prédios, incluindo-se os coeficientes de eficiência energética para os sistemas de refrigeração/aquecimento. Os resultados mostraram que os modelos para a emissão de dióxido de carbono alcançaram R^2 de 99,8% e 99,9% na situação de refrigeração e aquecimento, respectivamente, com erros abaixo de 0,0008. Já o modelo de regressão linear alcançou, nas duas situações avaliadas, valores de R^2 próximos a 85% com erros entre 0,027 a 0,061. Portanto, o estudo demonstrou a superioridade que um modelo com base em uma RNA possui em relação a um modelo linear para a predição das emissões de dióxido de carbono em uma situação não linear, cujas relações entre as emissões e os indicadores disponíveis não são claras e intuitivas.

Khashman et al. (2016) modelaram uma RNA com o algoritmo de Retropropagação para predizer as emissões de dióxido de carbono provenientes do agronegócio da Turquia, que é o setor de maior influência na economia do país. O estudo utilizou quatro variáveis de entrada, sendo elas o consumo total de energia pela agricultura, o PIB real do setor agrícola, o PIB ao quadrado e a demanda por produtos agrícolas. O banco de dados para a pesquisa contemplou os anos de 1968-2010 para o treinamento e teste da RNA. Os autores modelaram 3 RNAs com 3 camadas cada uma (entrada, oculta e saída), variando o número de neurônios na camada oculta. Após a otimização das redes, percebeu-se que a RNA com 5 neurônios na camada oculta forneceu o modelo com o menor erro médio quadrático que foi de 0,000908. Os autores concluíram que a modelagem com a RNA e o algoritmo de Retropropagação foi adequada para identificar as relações não lineares entre os indicadores principais do setor agrícola da Turquia e as suas emissões de dióxido de

carbono. Com base nesses resultados, os autores sugeriram novos estudos na área, para identificar o indicador de maior relevância nas emissões. Uma vez encontrado, esse indicador pode ser mais bem avaliado, possibilitando sugestões de políticas e estratégias governamentais sobre o setor agrícola da Turquia, de modo que ela possa reduzir suas emissões de dióxido de carbono.

Taghavifar et al. (2016) avaliaram o potencial de uma RNA com o algoritmo de Retropropagação para prever as emissões de dióxido de carbono, NO_x e fuligem provenientes da queima de um combustível a base de n-heptano. Os autores simularam a queima do combustível por uma aproximação em CFD (*Computational Fluid Dynamics*). O menor erro médio quadrático foi alcançado com 18 neurônios artificiais na camada oculta e o R^2 encontrado para a emissão de dióxido de carbono foi de 0,9976. Dessa forma, os autores demonstram que uma RNA com o algoritmo de Retropropagação é uma ferramenta adequada para a predição de poluentes atmosféricos, como o dióxido de carbono, a partir do consumo de combustíveis fósseis. Sendo assim, fica claro, mais uma vez, a capacidade da RNA em encontrar a correlação entre o consumo de combustíveis fósseis e o seu impacto na emissão de dióxido de carbono.

Cappizi et al. (2015) modelaram uma RNA do tipo cascata, que conecta cada indicador estudado diretamente em todas as camadas da rede, para prever as concentrações de poluentes atmosféricos em Catania, na Itália. As substâncias avaliadas foram o NO_2 , NO , NO_x e o PM_{10} (partículas inaláveis de diâmetro inferior a 10 micrometros). Os autores coletaram dados de 288 horas em duas estações próximas de monitoramento da qualidade do ar no ano de 2012 para treinar a RNA de modo que ela pudesse prever a concentração dos poluentes em uma terceira estação que operava em condições semelhantes às outras duas. O algoritmo de treinamento utilizado foi o de Retropropagação e o erro médio quadrático obtido foi de 0,0065315. O estudo concluiu que a RNA modelada é capaz de prever com acurácia aceitável a concentração dos poluentes atmosféricos de forma semelhante ao que faria a terceira estação de monitoramento analisada. Desse modo, o modelo proposto tem potencial para reduzir os equipamentos de instrumentação e as próprias estações de monitoramento. Com essa substituição, haveria economia com

equipamentos, operadores e manutenções que uma estação de monitoramento possui. Para alcançar tal objetivo, os autores ressaltam a necessidade de mais estudos com os modelos de RNA para que no futuro, eles possam incluir em suas entradas as condições meteorológicas, deixando o modelo mais adequado e preciso em diversas situações. Sendo assim, percebe-se a capacidade que a RNA tem, não somente em prever a concentração dos poluentes, mas também de substituir uma estação de monitoramento do ar.

A alta complexidade entre as emissões de poluentes atmosféricos e seus indicadores de maior relevância dificulta a utilização de modelos matemáticos tradicionais. Enquanto isso, modelos não lineares, como as Redes Neurais Artificiais, conseguem prever com acurácia essas emissões, além de relacioná-las a indicadores relevantes. Com os alertas internacionais a respeito do aquecimento global, vários estudos estão sendo desenvolvidos a partir de Redes Neurais Artificiais, a fim de preverem as emissões de dióxido de carbono nos países com maior emissão. Nesse cenário, o Brasil ocupou a 13ª posição dos maiores emissores de dióxido de carbono em 2013 (Carbon Global Atlas, 2021). Portanto, faz-se necessário o estudo que compreenda o perfil de sua emissão, bem como o desenvolvimento de modelos que contribuam com sua política energética para reduzi-la. Sendo assim, os estudos que preveem as futuras emissões de dióxido de carbono para o Brasil têm por objetivo, compreender suas principais causas e propor alternativas para reduzi-las.

2.17.8 Modelagens para a predição das emissões de CO₂ no Brasil

O Brasil faz parte do chamado "BRICS", que corresponde a cinco países (Brasil, Rússia, Índia, China e África do Sul) caracterizados pelo forte crescimento econômico e industrial associados à alta taxa de emissão de gás carbônico. Devido a maior preocupação em relação ao aumento da temperatura global e seus impactos no meio ambiente e no modelo socioeconômico contemporâneo, vários estudos têm sido desenvolvidos com o intuito de prever a tendência das emissões de gases do efeito estufa, com ênfase no CO₂. Nesse cenário, alguns estudos avaliaram a tendência das emissões de gás carbônico para o Brasil e constataram que ela é

crescente. Uma vez que o Brasil se comprometeu a reduzir as suas emissões em 43% até 2030 no Acordo de Paris, esses estudos alertam que é necessário o desenvolvimento de estratégias pelo governo brasileiro de modo que suas emissões sejam reduzidas. Entretanto, os estudos que avaliaram a tendência das emissões de gás carbônico no Brasil para os próximos anos consideraram essas emissões como uma série temporal, ou seja, avaliaram a variável estudada em função do tempo. Apesar desses modelos serem úteis em mostrar o comportamento futuro das emissões brasileiras, eles são limitados, uma vez que não apresentaram nenhuma intervenção quantitativa que ajude o Brasil a reduzi-las.

Uma pesquisa desenvolveu um modelo preditivo para as emissões de gás carbônico dos países "BRICS". Foram utilizados dados entre os anos 2000 e 2018 e as predições realizadas foram feitas para o período de 2019-2025. Os autores utilizaram o *Grey Model* e constataram, para o Brasil, o aumento das suas emissões de gás carbônico ano após ano (WU et al., 2020). A partir disso, os autores sugerem que o governo brasileiro tome maiores medidas para reduzir as suas emissões de CO₂. Entretanto, o artigo não se aprofundou em estudar os motivos pelos quais as emissões brasileiras de CO₂ devem aumentar nos próximos anos e nem sugeriram estratégias concretas pelas quais o Brasil poderia reduzir essas emissões.

Cone e Buke (2010) realizaram predições para as emissões de gás carbônico nos 25 países mais emissores do mundo. Para isso, os autores utilizaram as séries temporais (emissão de CO₂ em função do ano) do período entre 1971-2007. A partir desse banco de dados, foram realizadas as análises de regressão para cada país para se obter a equação de tendência para a emissão de gás carbônico no período entre 2008-2010. Apesar de não especificarem o R² do modelo de cada país, esses valores variaram de 0,900 a 0,9783, sendo considerados como bons pelos autores. Em relação ao Brasil, o estudo percebeu uma tendência crescente para as emissões de CO₂ que seria de aproximadamente 381,65 (Mt) e 478,61 (Mt) nos anos de 2015 e 2030, respectivamente (KONE; BUKE, 2010). Sendo assim, fica claro a necessidade de intervenção do governo brasileiro a fim de se reduzir as emissões de gás carbônico. Mais uma vez, percebemos que a tendência do Brasil é o aumento de suas emissões de gás carbônico nos próximos anos. Porém, se o governo brasileiro

quiser de fato cumprir o Acordo de Paris e contribuir com a sustentabilidade global, faz-se necessário investigar de forma mais profunda as principais causas das suas emissões de CO₂ para que elas possam ser reduzidas.

Pao e Tsai (2011) fizeram modelos preditivos para as emissões de gás carbônico, consumo de energia e para o crescimento econômico do Brasil. Os autores utilizaram o *Grey Model* para analisar o comportamento das variáveis estudadas entre os anos de 1980 e 2007 e para predizê-las entre os anos de 2008 a 2013. A partir da análise dos resultados, os autores encontraram uma relação entre as emissões de gás carbônico no Brasil e o seu consumo de energia. Foi verificado que ao se consumir mais energia no país há uma maior emissão de CO₂. Com isso, o artigo sugere que o governo brasileiro deve investir no setor de energia a fim de torná-lo mais eficiente, reduzindo assim o desperdício de energia. A partir dessa estratégia, os autores acreditam que será possível reduzir as emissões de gás carbônico no Brasil, sem que haja prejuízos no seu desenvolvimento econômico (PA NEIRO; RAFAEL, 2020). Nesse estudo, começamos a compreender melhor as emissões brasileiras de CO₂. Já que os autores demonstraram uma relação positiva entre o consumo de energia com as emissões e que um setor energético mais eficiente pode contribuir com as emissões de gás carbônico, é plausível propor mais estudos que se aprofundem nas relações entre essas emissões com a matriz energética brasileira. Com isso, seria possível avaliar melhor quais são as fontes de energia que possuem maior ou menor impacto na emissão de CO₂, permitindo assim, estratégias mais assertivas por parte do governo brasileiro.

Schulz e Ruppenthal (2018) aplicaram a metodologia *Box & Jenkins* para estudar a série temporal das emissões de gás carbônico no Brasil entre os anos de 1960 a 2013. Após a análise dessas emissões nesse período, os autores concluíram que a série temporal estudada não está em fase estacionária, apresentando uma tendência de crescimento ao longo dos anos. Dessa forma, os autores enfatizam a importância do investimento em tecnologias limpas e de baixo carbono, a fim de reduzir as emissões de CO₂ no Brasil, sem contudo, comprometer a produtividade do seu sistema econômico (SCHULZ; RUPPENTHAL, 2018). Mais uma vez, percebemos a tendência de aumento das emissões brasileiras de CO₂ para os

próximos anos. Os autores também incentivaram o uso de energia limpa para o Brasil. Entretanto, são necessários estudos que investiguem de forma mais aprofundada o quanto esse investimento em recursos renováveis pode, de fato, reduzir as emissões de gás carbônico no país. Essa avaliação quantitativa é portanto, imprescindível para que políticas e estratégias no setor energético do Brasil possam ser tomadas de modo a não limitarem o crescimento econômico do país.

S. Ahmed, K. Ahmed e Ismail (2020) utilizaram o *Grey System Theory* para predizerem as emissões de gás carbônico nos "BRICS" em função do desenvolvimento econômico, do surgimento de novas tecnologias e do consumo de energia. Para o Brasil, os autores utilizaram o banco de dados para cada variável entre o período de 1990 a 2014 e conseguiram predizer as emissões de CO₂ entre 2015 e 2024. Com base nos resultados, os autores verificaram um forte aumento das emissões de gás carbônico no Brasil pelos próximos anos. Essa tendência é justificada pela forte dependência que o país possui dos combustíveis fósseis. Todavia, os autores indicaram que a maior utilização de energia renovável pode contribuir para a redução das emissões de gás carbônico no Brasil, contribuindo para a sustentabilidade do planeta (AHMED; AHMED; ISMAIL, 2020). Aqui, fica claro que o setor energético brasileiro é uma peça-chave na busca por um desenvolvimento sustentável. Entretanto, faltam ainda estudos que demonstrem quantitativamente o quanto a menor utilização de recursos fósseis e a maior contribuição dos recursos renováveis podem impactar nas emissões brasileiras de gás carbônico.

Acheampong e Boateng (2019) utilizaram uma Rede Neural Artificial para predizer as emissões de gás carbônico para o Brasil, dentre outros países, em função dos parâmetros: crescimento econômico, consumo de energia, pesquisa e desenvolvimento, desenvolvimento financeiro, investimento estrangeiro, industrialização, urbanização e abertura de comércio. A estrutura neural utilizada foi a *Feed Forward Multi-Layer Perceptron* com o algoritmo de Propagação Retrógrada. Os resultados indicaram que as emissões brasileiras de gás carbônico possuem uma tendência crescente e que a urbanização é o parâmetro de maior contribuição (ACHEAMPONG; BOATENG, 2019). Desse modo, o estudo contribui de forma

significativa na avaliação do comportamento das emissões de gás carbônico no Brasil, entretanto, não propõem nenhuma estratégia quantitativa para que essas emissões sejam reduzidas a fim de respeitarem o Acordo de Paris.

Filho, Aquino e Neto (2020) estudaram a emissão de gás carbônico no Brasil em função da intervenção nos preços dos combustíveis derivados do petróleo e no seu substituto, o etanol. O estudo abrangeu os valores para os combustíveis estudados no período de 2002 a 2016, sendo que nessa época, houve intervenção política que impactou os preços de combustíveis no Brasil. Os resultados, obtidos em uma regressão multivariada, indicaram que a intervenção política para o controle do preço dos combustíveis a base de petróleo incentivou o consumo desses e desfavoreceu o consumo de etanol, contribuindo para o aumento das emissões de gás carbônico (FILHO; AQUINO; NETO, 2020). Os autores estimaram que se o governo não tivesse interferido no controle dos preços dos combustíveis a base de petróleo, o aumento das emissões de gás carbônico seriam 50% menor. Sendo assim, percebe-se a influência que medidas políticas possuem nas emissões de gás carbônico de um país. Isso ocorre, porque as intervenções nos setores energéticos, de transporte e de marketing podem incentivar ou não o consumo de produtos altamente poluentes.

Bildirici (2018) estudou as correlações entre a militarização, o consumo de biocombustíveis, o crescimento econômico e as emissões de gás carbônico para o Brasil, para os Estados Unidos e para a China. Para as variáveis estudadas, o autor coletou dados entre 1985 a 2015 e aplicou o método *The Autoregressive Distributed Lag*, além de outros testes e metodologias de investigação para a correlação entre variáveis. A partir dos resultados obtidos, Bildirici conclui, para o Brasil, que a militarização e o crescimento econômico possuem uma correlação bilateral, isto é, o crescimento econômico do país colabora com o desenvolvimento de suas Forças Armadas, assim como o avanço na área militar favorece o crescimento econômico brasileiro. Além disso, o aumento dessas variáveis intensifica as emissões de CO₂ no Brasil, enquanto que a maior utilização dos biocombustíveis as diminui (BILDIRICI, 2018). Com base nesse estudo, percebe-se a correlação entre o crescimento econômico e a militarização brasileira com as emissões de gás

carbônico. A explicação para isso, segundo o autor, se dá pelo fato de que as Forças Armadas demandam um alto consumo de combustíveis fósseis para abastecer seus navios, veículos, jatos, submarinos, dentre outros. Somando-se a isso, o crescimento econômico, também incentiva a maior produção e consumo de bens e serviços pela população, exigindo maior consumo energético que contribui com as emissões de CO₂. Em contrapartida, a utilização dos biocombustíveis reduz essas emissões, visto que são obtidos majoritariamente por fontes renováveis que no processo de renovação da safra absorvem parte do CO₂ atmosférico.

Réquia et al. (2016) fizeram uma análise espaço-temporal em mais de 5 mil municípios brasileiros. O estudo partiu, principalmente, do fato de que apenas 1,7% das cidades brasileiras possuem um monitoramento de poluição atmosférica e de que há poucos trabalhos em relação a emissão de poluentes por veículos nesses distritos (RÉQUIA et al., 2016). Desse modo, os autores utilizaram o método *Top-Down* para predizerem os principais poluentes atmosféricos emitidos pelos veículos brasileiros no período de 2001 a 2012. Os resultados indicaram que o CO₂ foi o principal gás emitido, totalizando 190 milhões de toneladas/ano, no período avaliado (RÉQUIA et al., 2016). Apesar da emissão de alguns poluentes ter diminuído ao longo dos anos, possivelmente devido o surgimento de melhores tecnologias nos escapamentos de automóveis e de leis ambientais mais rigorosas, o estudo constatou que isso não ocorreu no caso do gás carbônico, cujas emissões vem aumentando. Sendo assim, fica evidente a necessidade de uma maior consciência em relação às altas emissões de CO₂ geradas pelo tráfego de veículos nas cidades brasileiras, pois apesar desse poluente não ser tóxico, contribui de forma significativa para o aumento da temperatura global, bem como danos à sustentabilidade do planeta.

Andrade e D'Agosto (2016) estudaram a influência do sistema ferroviário na redução das emissões de gás carbônico na cidade do Rio de Janeiro, no Brasil. O estudo informa que a fim de se alcançar em 2020 a redução de 20% das emissões de CO₂ em relação a 2005, houve uma reestruturação do setor de transporte público nesse município (ANDRADE; D'AGOSTO, 2016). Para que esse objetivo fosse atingido, a prefeitura enfatizou a utilização do sistema ferroviário, a partir da criação de uma

nova linha de metrô, visando a diminuição do consumo dos combustíveis fósseis por outros meios de transporte. Os autores utilizaram um modelo de demanda detalhada e com ele, previram que entre 2016 e 2040 a nova linha de metrô evitará a emissão de 55,449 mil toneladas de gás carbônico por ano. Ademais, os autores concluíram que a estratégia política adotada economizará 0,76 (MJ/passageiro km). A partir dessa análise, fica claro que a intervenção política, que nesse caso utilizou um sistema de transporte público mais eficiente do ponto de vista energético, contribui de forma significativa na redução das emissões de gás carbônico. Com isso, percebe-se a importância do planejamento político em relação aos setores energéticos e produtivos, visto que o incentivo e a busca por tecnologias mais limpas e eficientes tem um efeito considerável na emissão de CO₂.

2.18 Considerações Finais

Em suma, a revisão do estado da arte mostrou os impactos negativos que o aquecimento global acelerado pelas altas concentrações de dióxido de carbono na atmosfera tem sobre os ecossistemas e a sociedade. Percebeu-se que a grande emissão de dióxido de carbono é proveniente do alto consumo energético mundial, que por sua vez, é abastecido por uma matriz energética dependente dos combustíveis fósseis, cuja queima libera esse poluente. Por esse motivo, é imprescindível que os países tomem medidas eficazes para reduzir suas emissões de dióxido de carbono, a fim de se obter um futuro sustentável. Para alcançar esse objetivo, faz-se necessário, o planejamento de longo prazo para os setores energéticos de cada país, pois a partir dele, é possível identificar os principais recursos energéticos de cada nação que abastecem seus setores econômicos, que são os principais consumidores finais de energia e emissores de dióxido de carbono. A partir dos dados da matriz energética e de outros fatores próprios de cada país, pode-se encontrar os impactos que eles causam nas emissões de dióxido de carbono. Desse modo, seria possível propor políticas e estratégias públicas, que diminuam, quando possível, os indicadores que mais contribuem para as emissões de dióxido de carbono.

O maior desafio em se relacionar as emissões de dióxido de carbono e os diversos indicadores, sejam eles econômicos ou sociais, particulares de cada nação, é a complexa não linearidade entre essas variáveis. Sendo assim, os modelos computacionais tradicionais e lineares não conseguem encontrar, de forma satisfatória, essas relações, havendo a necessidade de novas abordagens. Nesse contexto, as Redes Neurais Artificiais apresentam-se como ferramentas eficazes na identificação de padrões e correlações não lineares entre uma resposta (as emissões de dióxido de carbono) e possíveis variáveis que possam influenciá-la. A revisão da literatura deixou claro que autores conseguiram, a partir de RNAs, prever, com acurácia aceitável, as emissões de dióxido de carbono em diferentes países a partir de seus indicadores. Além disso, a literatura mostrou recorrência para alguns desses indicadores, independentemente da nação estudada, sendo eles a população do país, seu PIB, a temperatura média anual, o consumo de energia elétrica e total, bem como a participação que cada fonte energética teve nesse consumo final. Para o Brasil, em particular, notamos que alguns trabalhos realizados consideraram as emissões de CO₂ como uma série temporal. Apesar desses estudos mostrarem uma tendência crescente para as emissões brasileiras de gás carbônico nos próximos anos, eles são limitados, pois não fornecem nenhuma estratégia prática e quantitativa para a redução dessas emissões. Os estudos que avaliaram as emissões de CO₂ no Brasil em função de outras variáveis, como o PIB, a população, o consumo energético no país, dentre outras, mostraram de forma qualitativa que a redução de algumas dessas variáveis pode contribuir com a redução das emissões de gás carbônico no Brasil. Todavia, essas pesquisas são limitadas, uma vez que não ofereceram nenhuma estratégia quantitativa para a redução das emissões de CO₂, a fim de que o Brasil respeite o Acordo de Paris. Outra limitação desses trabalhos, é o fato de que eles consideraram o consumo de energia total do Brasil, sem que a sua matriz energética fosse detalhada de acordo com as diferentes fontes de energia do país. Desse modo, não foi encontrado nenhum artigo que avaliasse a contribuição particular de cada fonte de energia na emissão de CO₂ no Brasil, de modo a propor mudanças quantitativas na matriz energética brasileira que sejam eficientes na redução das emissões de gás carbônico. Outro fator que não foi considerado nos modelos existentes para a predição das emissões de CO₂ no Brasil, é o índice de queimadas no país. Sendo

assim, é imprescindível o desenvolvimento de novos modelos preditivos que incluam as particularidades da matriz energética brasileira e também os focos de queimadas na Amazônia e nos demais biomas do Brasil.

Diante disso, a modelagem de uma RNA para as emissões de gás carbônico no Brasil, que utilize os indicadores mais relevantes ao país, tem grande potencial de prever as suas futuras emissões de dióxido de carbono a longo prazo de forma acurada. Com esse modelo disponível, seria possível identificar se, com base nos dados históricos e do Planejamento Energético 2050 do Brasil, o país conseguirá reduzir suas emissões de modo a atingir suas metas propostas no Acordo de Paris. Caso as metas não sejam atingidas, o modelo também abre a oportunidade de identificar quais são os indicadores que mais afetam as emissões de dióxido de carbono no Brasil e, com isso, analisar de forma mais profunda os ajustes que podem ser feitos em cada um deles. A partir daí, seria então possível, ter clareza a respeito das políticas, estratégias e investimentos necessários no setor energético, ou qualquer outro que tenha grande impacto nas emissões. Desse modo, seria possível propor mudanças quantitativas nas variáveis estudadas para que o Brasil reduza suas emissões de CO₂, e assim atenda as metas acordadas internacionalmente, além de construir a base de um futuro sustentável.

3 MATERIAIS E MÉTODOS

3.1 ATIVIDADES PRINCIPAIS

A fim de modelar uma Rede Neural Artificial capaz de prever adequadamente as emissões brasileiras de dióxido de carbono e relacioná-las com indicadores socioeconômicos relevantes do país, foram seguidos os 6 passos a seguir:

- 1) Identificar os principais indicadores brasileiros relacionados a emissão de CO₂;
- 2) Obter junto ao Ministério de Minas e Energia do Brasil os dados dos indicadores brasileiros relacionados a emissão de CO₂ e do perfil da matriz energética do país desde 1970;
- 3) Tratar e normalizar os dados obtidos;
- 4) Construir, modificar, treinar, testar e validar uma RNA para que obtenha a melhor acurácia;
- 5) Prever as emissões brasileiras de CO₂ até 2030;
- 6) Sugerir mudanças na matriz energética brasileira para se obter uma menor emissão de CO₂ em 2030.

3.2. COLETA DE DADOS PARA AS ENTRADAS E SAÍDAS DA RNA

Com o intuito de relacionar as emissões brasileiras de CO₂ a parâmetros relevantes, escolhemos nove indicadores para nossa RNA:

- 1) PIB (Produto Interno Bruto)
- 2) População (P)

- 3) Fornecimento Total de Energia Primária (FTEP)
- 4) Consumo de Eletricidade (CE)
- 5) Participação de fontes de energia renovável no FTEP (Fontes Renováveis)
- 6) Participação de gás natural no FTEP (Gás Natural)
- 7) Participação total de petróleo e seus derivados no FTEP (Produtos Petrolíferos)
- 8) Participação de carvão mineral e outros recursos fósseis em FTEP (CM)
- 9) Incêndios na Floresta Amazônica e em outros biomas brasileiros (Queimadas)

Esses nove indicadores serviram de entrada para as Redes Neurais Artificiais modeladas nesse estudo. Os dados em relação a esses indicadores foram coletados do Banco Mundial (World Bank, 2021), do Atlas Global de Carbono (Carbon Global Atlas, 2021) e do Sistema Brasileiro de Informações sobre Energia (SIE, 2021) entre 1998 – 2018, sendo esses bancos de dados reconhecidos por sua confiabilidade e credibilidade. Para simular as emissões brasileiras de CO₂ entre 2019 - 2030, fizemos uma regressão linear dos nove indicadores para servir de entrada à rede no mesmo período. A escolha desses nove indicadores se deu ao fato de que, teoricamente, eles estão relacionados às emissões de CO₂, aparecem com frequência em estudos semelhantes (DOZIC; UROSEVIC, 2019; PAO; TSAI, 2011; PINO-MEJIAS et al., 2017)) e porque os dados desses indicadores nos últimos anos são facilmente acessíveis. Além disso, o uso desses nove indicadores simultaneamente para prever emissões de CO₂ é inédito na literatura. Vale ressaltar também, que não foram encontrados estudos preditivos das emissões brasileiras de CO₂ que utilizaram as queimadas nos biomas como indicador.

Para facilitar e otimizar o aprendizado da RNA, normalizamos esses indicadores com base na Equação 8, uma vez que a magnitude dos dados difere para cada indicador.

$$\text{Indicador Normalizado} = \frac{x - X_{\min}}{X_{\max} - X_{\min}} \quad (8)$$

Em que, x é o valor a ser normalizado, X_{\min} e X_{\max} são os valores mínimo e máximo obtidos para o indicador no período avaliado, respectivamente.

A Figura 14 mostra os valores normalizados para a regressão linear dos nove indicadores.




Figura 14. Indicadores socioambientais brasileiros normalizados para o período de 1998 a 2018.

A partir da Figura 14, percebemos que indicadores como o PIB, a população, o consumo de energia elétrica e total no Brasil (bem como as suas fontes) possuem tendência de crescimento nos últimos anos. Já as queimadas nos biomas brasileiros apresentaram valores elevados entre os anos de 2002 e 2007, atingindo valores mais baixos a partir daí, devido aos esforços do Brasil em combater o desmatamento ilegal.

3.3. ESTRUTURA DA REDE NEURAL ARTIFICIAL

Nesse trabalho, nós utilizamos o software Matlab R2020a para a modelagem de Redes Neurais Artificiais. Essas redes tinham por objetivo conhecer o complexo

sistema de energia do Brasil. A partir desse aprendizado, esperávamos obter a predição das emissões brasileiras de CO₂ entre os anos de 2019 a 2030. Com esse fim, escolhemos as arquiteturas *Cascade Feed Forward Back Propagation* (CFFBP) e *Feed Forward Back Propagation* (FFBP). Essa escolha foi feita com base no grande número de estudos que as utilizaram para fins semelhantes. O CFFBP tem alta capacidade de aprender problemas complexos e as possíveis dependências entre as entradas. Isso é possível pelo fato de que nessa arquitetura cada entrada está conectada a cada camada da rede. Assim, a rede pode identificar mais correlações entre as entradas e a saída do modelo. Essa característica, permite que a rede obtenha pesos mais precisos para as variáveis e, conseqüentemente, erros menores. Já a arquitetura FFBP é uma das mais utilizadas para problemas complexos em que a saída da rede dependente de mais de uma variável de entrada. Essa estrutura de rede funciona de forma semelhante ao CFFBP. No entanto, as variáveis de entrada não estão conectadas diretamente às camadas seguintes da rede. Sendo assim, na FFBP as entradas são conectadas apenas à próxima camada. Só depois que os neurônios artificiais processam essa informação é que ela segue para a próxima camada e assim por diante. As Figuras 15 e 16 mostram as estruturas modeladas nessa pesquisa para as RNAs CFFBP e FFBP, respectivamente.




Figura 15. Exemplo de uma Rede Neural Artificial do tipo *Cascade Feed Forward Back Propagation* (MATLAB, 2020).




Figura 16. Exemplo de uma Rede Neural Artificial do tipo *Feed Forward Back Propagation* (MATLAB, 2020).

Para cada uma dessas 2 estruturas, nós variamos o número de camadas ocultas entre 1 e 2. O número de neurônios em cada camada variou entre 1 e 9. Além disso, para cada estrutura testada, o RNG (*Random Number Generator*) variou de 0 a 100. Portanto, ao longo dessa pesquisa foram simuladas 18.000 RNAs, seguindo os passos dos códigos do APÊNDICE B.

As camadas ocultas são conhecidas por permitirem que a RNA calcule novos pesos para entradas. Dessa forma, a RNA é capaz de representar com precisão o estado do sistema investigado e prever uma saída adequada. No entanto, nesse estudo, não utilizamos um banco de dados muito extenso (1998 a 2018, com dados anuais). Portanto, decidimos manter o número de camadas ocultas o menor possível.

Na busca por representações fidedignas de sistemas complexos, as RNAs apresentam uma grande vantagem em relação aos métodos tradicionais ao utilizarem funções de ativação não lineares. Essas funções transformam as entradas de forma não linear no neurônio artificial. Dessa forma, esse processo permite que as RNAs criem relações não lineares entre neurônios e camadas. Com isso, pode-se obter uma dependência não linear entre a saída e as entradas da rede, o que permite a solução de problemas complexos reais.

Nesse estudo, nós utilizamos a função de *Levenberg-Marquardt*, que tem mostrado bons resultados na literatura em pesquisas semelhantes (FU; HAN; CHEN, 2022; DESHPANDE; MODI; SANT, 2022; CHEN; JUNGSTEDT, 2022). A Figura 17 mostra um exemplo de uma função de ativação não linear do tipo sigmóide.




Figura 17. Representação gráfica da saída de uma função de ativação sigmoideal.

Fonte: Retirada da Internet.

3.4. TREINAMENTO DA REDE NEURAL ARTIFICIAL

Os dados coletados no período de 1998 a 2018 foram utilizados para o treinamento, teste e validação das RNAs. Os dados foram divididos aleatoriamente em 3 grupos:

- 1) 65% para o treinamento;
- 2) 17,5% para o teste;
- 3) 17,5% para a validação das redes.

4.4. PROCESSO DE VALIDAÇÃO E ANÁLISE DE ERROS

Neste artigo, modelamos e simulamos 18.000 RNAs. No entanto, apenas RNAs que atendiam aos quatro critérios especificados abaixo foram utilizadas para simulações de análise de cenários.

- 1) O erro quadrático médio dos dados testados é $< 0,02$ (2%) (DOZIC; UROSEVIC, 2019);
- 2) A saída de RNAs é mais afetada por mudanças na entrada do indicador de produtos petrolíferos do que a entrada do indicador de fontes renováveis;
- 3) As emissões de CO_2 aumentam com maior consumo de fontes de energia de combustível fóssil;

- 4) As previsões encontradas para as emissões brasileiras de CO₂ concordam com outras previsões presentes na literatura (KONE; BUKE, 2010).

Para analisar a sensibilidade da saída das RNAs em relação às variações nas entradas, utilizou-se o método *Mean Impact Value* (MIV), de acordo com o seguinte algoritmo:

- 1) Após treinar a RNA, transformamos cada valor da variável de entrada em mais e menos 10%. Dessa forma, conseguimos novos insumos ($P_1 \dots P_9$ e $M_1 \dots M_9$). O conjunto P_n representa cada variável de entrada com um acréscimo de 10% em seu valor original. O conjunto M_n representa cada variável com uma diminuição de 10% em seu valor original;
- 2) P_n e M_n foram as entradas para a RNA treinada, e dois resultados de simulação, YP_n e YM_n , respectivamente, foram obtidos para cada variável;
- 3) As diferenças entre YP_n e YM_n foram calculadas. Estes foram os valores de impacto (VI) das mudanças na variável de entrada na saída;
- 4) A média dos Valores de Impacto foi calculada pelo número de observações. Com isso, obtivemos o MIV de cada variável na variável dependente.

Esta metodologia foi adaptada de Tan e Zhang (2018). As variáveis independentes que têm um valor de MIV mais alto terão um impacto mais significativo nas emissões de dióxido de carbono.

3.5. ANÁLISE DAS SIMULAÇÕES DE CENÁRIOS

Apenas as RNAs que passaram nos quatro critérios estabelecidos passaram a analisar cenários. Para isso, simulamos dois cenários específicos:

- 1) Propomos que, até 2030, o Brasil reduzirá 30% da participação de derivados de petróleo, gás natural e outros combustíveis fósseis em seu FTEP. Para isso, reduzimos a tendência de cada um desses indicadores em 2,5%, cumulativamente, ao ano. Além disso, para manter o equilíbrio da matriz energética, todas essas reduções foram somadas à participação de fontes renováveis de energia ano após ano. Também consideramos que até 2030

70% dos incêndios na floresta amazônica e outros biomas serão reduzidos. Assim, reduzimos a tendência deste indicador em 5,85% ao ano para obter o valor de uma redução de 70,20% em 2030;

- 2) Este cenário é semelhante ao primeiro. No entanto, a redução da participação dos recursos não renováveis no FTEP foi de 90%. Também consideramos uma redução de 90% nos incêndios na floresta amazônica e outros biomas. Todas as reduções na contribuição de recursos fósseis foram adicionadas à parcela de recursos renováveis;

Com base nos resultados da análise do cenário, será possível discutir se o Brasil está ou não em um caminho que atinge as metas do Acordo de Paris. Além disso, a análise de cenários apresenta-se como uma ferramenta poderosa para criar uma estratégia que possa efetivamente reduzir as emissões brasileiras de CO₂.

Ao alterar significativamente a matriz energética brasileira, é válido questionar como isso pode afetar o PIB. Se a substituição de recursos fósseis por recursos renováveis impactar o PIB do Brasil, ele não mais se comportará como descrito na sua regressão linear. Portanto, só faz sentido utilizar os dados do PIB encontrados pela sua regressão linear se esse indicador for independente das alterações na matriz energética.

Existe uma vasta literatura sobre consumo de energia e crescimento do PIB. No entanto, ainda não há consenso se o aumento do consumo de energia favorece o crescimento do PIB ou se é o crescimento do PIB que demanda maior consumo de energia (MAHALINGAM; ORMAN, 2018). A relação entre o PIB e o consumo específico de energia de fontes renováveis ainda não é conclusiva. No entanto, existem estudos que não encontraram uma relação causal entre o consumo de energia renovável e o PIB (MOUNIR; EL-HOUJJAJI, 2022; BAO; XU, 2019; EL-KARIMI, 2022; DOGAN, 2015; IVANOVSKI; HAILEMARIAM; SMYTH, 2021; SMOLOVIC et al., 2020; BULUT; MENEGAKI, 2020; TUNA G; TUNA V, 2019). Embora alguns resultados tenham encontrado uma relação causal entre o consumo de fontes renováveis de energia e o crescimento do PIB para alguns países, essa relação se mostrou significativa apenas no longo prazo (MOUNIR; EL-HOUJJAJI,

2022; IVANOVSKI; HAILEMARIAM; SMYTH, 2021; SMOLOVIC et al., 2020; DOGAN, 2015; CHEN; PINAR; STENGOS, 2020).

A partir desses estudos, fica claro que a relação causal entre o consumo de energia de fontes renováveis só existe, quando existe, no longo prazo. Portanto, como a análise de cenário proposta neste estudo é realizada no médio prazo, podemos dizer que a substituição parcial de recursos não renováveis por renováveis para o consumo de energia no Brasil não afetará significativamente o comportamento do seu PIB. Dessa forma, podemos utilizar a regressão linear feita para o PIB brasileiro entre 2019 e 2030, pois seu comportamento não será alterado significativamente pelas mudanças ocorridas na matriz energética do país no mesmo período para a análise dos cenários propostos.

4 RESULTADOS E DISCUSSÕES

4.1 SELEÇÃO DAS REDES NEURAIS E PREDIÇÕES DAS EMISSÕES DE CO₂

Com base em nossas modelagens, encontramos seis RNAs capazes de relacionar as emissões brasileiras de CO₂ em função das nossas nove variáveis de entrada. Nossas Redes apresentaram erros médios quadráticos menores do que 2%. Ressaltamos que, a variável de Queimadas nos Biomas Brasileiros ainda não foi estudada em modelos preditivos de emissões brasileiras de CO₂. No entanto, esse indicador é importante na tentativa de reduzir essas emissões e na busca do desenvolvimento sustentável para o Brasil. Sendo assim, com a inclusão dele nas entradas das RNAs, será possível determinar o quanto a redução das queimadas brasileiras pode contribuir com diminuição das emissões de dióxido de carbono no país. Além disso, a utilização do MIV permitiu que avaliássemos quais são as variáveis que mais impactam nas emissões brasileiras de CO₂. A partir disso, ficou claro que os combustíveis fósseis, em sua maioria, contribuem de forma mais significativa nessas emissões do que os combustíveis renováveis. Isso significa que a substituição parcial dos recursos fósseis pelos renováveis apresenta-se como uma estratégia viável na busca pela redução das emissões brasileiras de dióxido de carbono.

A partir da normalização dos dados históricos dos indicadores avaliados, foi possível modelar e simular dezoito mil Redes Neurais Artificiais. Entretanto, apenas seis apresentaram simultaneamente um erro médio quadrático menor ou igual a 2% e maior sensibilidade para as emissões de dióxido de carbono a partir de mudanças no consumo de combustíveis fósseis em comparação às mudanças no consumo de recursos renováveis. A Tabela 1 mostra para cada uma dessas seis redes a arquitetura utilizada (cascata ou linear), o número de camadas ocultas, o número de neurônios utilizados em cada camada oculta e o erro médio quadrático.

Tabela 1: Número de camadas ocultas, número de neurônios nas camadas e Erro Médio Quadrático para cada Rede Neural Artificial Modelada.

RNA	Nº de camadas ocultas	Nº de Neurônios	RNG	Erro Médio Quadrático
CFFBP 1	2	7-6	66	$2,33 \times 10^{-5}$
CFFBP2	2	4-3	3	$5,25 \times 10^{-5}$
FFBP1	2	5-5	3	$8,98 \times 10^{-5}$
FFBP2	2	5-8	16	$4,38 \times 10^{-15}$
FFBP3	2	7-6	26	$4,92 \times 10^{-5}$
FFBP4	2	9-4	33	$9,46 \times 10^{-5}$

CFFBP (*Cascade Feed Forward Back Propagation*) e FFBP (*Feed Forward Back Propagation*).

Com base na Tabela 1, percebemos que com apenas 1 camada oculta não foi obtida nenhuma RNA que satisfizesse as condições de ter um erro médio quadrático menor do que 2% e que apresentasse maior sensibilidade para a emissão de gás carbônico com o consumo de combustíveis fósseis em relação aos recursos renováveis. Por esse motivo, continuamos as nossas modelagens e simulações com 2 camadas ocultas e obtivemos seis RNAs que satisfizeram simultaneamente essas duas condições. Sendo assim, optamos por limitar em 2 camadas ocultas a nossa modelagem, devido ao fato do nosso banco de dados não ser extenso (dados para os anos de 1998 a 2018). Pela Tabela 1, também é possível conferir o número de neurônios artificiais usados em cada camada oculta e o RNG (*Random Number Generator*), que é um parâmetro que decide a aleatoriedade na escolha dos dados que servirão para o treinamento, teste e validação da rede. Desse modo, esses resultados mostram que as seis RNAs encontradas aprenderam a relação entre as emissões de dióxido de carbono em relação aos nove indicadores brasileiros avaliados. Portanto, essas seis RNAs apresentam-se como capazes, a priori, de imitar o complexo sistema energético do Brasil para predizerem as suas futuras emissões de dióxido de carbono. Em se tratando da sensibilidade dessas emissões em relação aos nove indicadores investigados, a Tabela 2 apresenta os resultados obtidos com a aplicação do algoritmo para o “Valor Médio de Impacto”.

Tabela 2: Ranqueamento da influência de cada indicador nas emissões brasileiras de CO₂.

Posição	CFFBP 1	CFFBP 2	FFBP 1	FFBP 2	FFBP 3	FFBP 4
1º	Consumo de Eletricidade	Consumo de Eletricidade	Consumo de Eletricidade	Consumo de Eletricidade	População	Consumo de Eletricidade
2º	FTEP	FTEP	População	População	FTEP	PIB
3º	Produtos Petrolíferos	Gás Natural	Gás Natural	PIB	Consumo de Eletricidade	Produtos Petrolíferos
4º	PIB	Produtos Petrolíferos	Produtos Petrolíferos	Produtos Petrolíferos	PIB	Gás Natural
5º	Gás Natural	PIB	Carvão Mineral	Fontes Renováveis	Produtos Petrolíferos	Carvão Mineral
6º	População	População	Queimadas	Gás Natural	Carvão Mineral	Queimadas
7º	Carvão Mineral	Carvão Mineral	FTEP	Carvão Mineral	Gás Natural	FTEP
8º	Fontes Renováveis	Fontes Renováveis	PIB	Queimadas	Queimadas	População
9º	Queimadas	Queimadas	Fontes Renováveis	FTEP	Fontes Renováveis	Fontes Renováveis

CFFBP (*Cascade Feed Forward Back Propagation*) e FFBP (*Feed Forward Back Propagation*);
 PIB (Produto Interno Bruto); FTEP (Fornecimento Total de Energia Primária).

A análise da Tabela 2 revela que, em geral, as emissões brasileiras de dióxido de carbono são muito influenciadas pelo consumo total de energia no país. Além disso, para as seis RNAs selecionadas, as emissões de dióxido de carbono possuem maior sensibilidade a alterações no consumo de combustíveis fósseis do que a alterações nos recursos renováveis. Desse modo, essas seis Redes Neurais Artificiais atenderam os dois primeiros critérios estabelecidos nessa pesquisa.

Após obtermos seis RNAs com erro médio quadrático aceitável e com maior influência do consumo de combustíveis fósseis sobre a saída de cada rede em relação ao uso de recursos renováveis, o próximo passo foi o de prever as emissões brasileiras de dióxido de carbono entre os anos de 2019 e 2030. Para isso, foi necessário a regressão linear de cada um dos nove indicadores a partir dos seus dados históricos (1998 a 2018), a fim de facilitar a extrapolação dessas variáveis, assim como feito em outro trabalho (DOZIC; UROSEVIC, 2019). A partir dessa

regressão linear, cada valor obtido foi normalizado de acordo com a Equação 8. A Figura 18 apresenta o valor normalizado para cada um dos nove indicadores para os anos de 2019 a 2030.




Figura 18. Tendência dos 9 indicadores brasileiros no período de 2019 – 2030.

A partir desses valores, é possível alimentarmos as seis RNAs selecionadas para predizermos as emissões brasileiras de dióxido de carbono entre 2019 e 2030. Esses valores serviram de entrada para as seis redes neurais artificiais já treinadas. Dessa forma, executamos os seis modelos de RNA e obtivemos a previsão das emissões brasileiras de CO₂ de 2019 a 2030. Esses resultados estão contidos na Figura 19.




Figura 19. Previsões de emissão brasileira de CO₂ de 2019 a 2030.

A partir da Figura 19, vemos que os dois modelos CFFBP apresentaram valores muito altos para as emissões brasileiras de CO₂ em comparação com os modelos FFBP. Também podemos ver que o CFFBP 1 obteve um valor extremamente alto para o ano de 2030. No entanto, os 6 modelos foram usados na etapa de análise de cenários. A partir da Figura 19, também observamos que as emissões brasileiras de CO₂ estão aumentando. Assim, o governo brasileiro deve investir em políticas energéticas para cumprir o Acordo de Paris. Entretanto, ainda não é possível afirmar que essas RNAs imitam de forma adequada a dependência das emissões brasileiras de dióxido de carbono e os 9 indicadores. Isso acontece porque o método "MIV" apenas nos informa o quão sensível é a saída das nossas redes em relação às suas entradas. Todavia, o "MIV" não nos informa se a relação entre a saída da rede e um indicador específico é uma relação positiva ou negativa. Isto é, sabemos apenas que o aumento ou a diminuição no consumo de petróleo e seus derivados terá maior impacto na emissão de dióxido de carbono do que uma modificação no consumo de recursos renováveis. Porém, não podemos ainda afirmar se esse aumento no consumo de um combustível fóssil provocará um aumento ou uma diminuição na emissão de dióxido de carbono. Tudo o que sabemos é que o impacto na saída da RNA a partir de variações no consumo de combustíveis fósseis será mais significativo. Sendo assim, na análise de cenários, o primeiro passo foi verificar quais

redes possuem a relação esperada entre os indicadores: Gás Natural, Produtos Petrolíferos e Carvão Mineral, e a saída da rede.

4.2 ANÁLISE DE CENÁRIOS

A partir da nossa análise de cenários, encontramos uma RNA (a FFBP 3) capaz de prever de forma confiável as emissões brasileiras de CO₂ entre 2019 e 2030. Com esse modelo, percebemos que a substituição parcial dos recursos fósseis pelos renováveis na matriz energética brasileira, bem como a diminuição das queimadas dos biomas no país, contribuem para a redução das emissões brasileiras de CO₂. No primeiro cenário em que analisamos, encontramos que a substituição parcial de 30% dos recursos fósseis pelos renováveis, juntamente com a redução de 70% das queimadas dos biomas do país, foram capazes de reduzir as emissões de dióxido de carbono em 13,58% para o ano 2030, em relação à situação em que essas mudanças não são realizadas. No segundo cenário proposto, consideramos uma substituição parcial dos recursos fósseis pelos renováveis de 90%, bem como a redução das queimadas também em 90%. Nesse caso, houve uma redução nas emissões brasileiras de CO₂ em 28,45% em 2030, comparando-se à situação em que as alterações propostas não foram realizadas. Desse modo, esses resultados contribuem com a literatura, uma vez que ainda não foram encontrados estudos que incluíram as queimadas nos biomas brasileiros como indicador nas emissões de dióxido de carbono no país. Além disso, os estudos presentes na literatura, apesar de sugerirem a maior utilização de recursos renováveis na matriz energética do Brasil, não foram capazes de mostrar quantitativamente o quanto essa estratégia contribui na redução das emissões de CO₂ pelo país.

Primeiro, alteramos os valores de entrada dos indicadores: Gás Natural, Produtos Petrolíferos e Carvão Mineral, um de cada vez, entre 2019 e 2030 para os 6 modelos de RNAs. Em seguida, observou-se que a redução no consumo de fontes de energia fóssil causou um aumento nas emissões de CO₂. Este efeito ocorreu para os modelos CFFBP1, CFFBP2, FFBP 1, FFBP 2 e FFBP 4. Assim, optamos por descartar esses modelos por não produzirem resultados coerentes.

O modelo FFBP 3 apresentou resultados conforme o esperado, pois as emissões preditas entre 2019 e 2023 ficaram próximas a ordem de grandeza de 500 Mt/ano que foram as emissões reais nesse período (*Global Carbon Atlas*, 2025) e a redução do consumo de fontes de energia fóssil provocou a redução das emissões de dióxido de carbono. Além disso, as emissões de CO₂ foram menores quando a quantidade de recursos fósseis foi substituída por fontes de energia renovável. Também foi observado que a redução de incêndios na floresta amazônica reduziu as emissões de CO₂. Portanto, concluímos que o modelo FFBP 3 representa corretamente o complexo sistema brasileiro. Por esse motivo, utilizamos apenas esse modelo para a análise de cenários de forma a encontrarmos as mudanças necessárias na matriz energética brasileira para que o país alcance as metas do Acordo de Paris em 2025 e 2030. Além disso, o APÊNDICE C apresenta os gráficos gerados no Matlab comprovando que o modelo FFBP 3 não apresentou *overfitting*.

Para a análise dos cenários, é preciso ter em mente as metas propostas pelo Brasil no Acordo de Paris para limitar o aquecimento global e suas consequências. O governo brasileiro propôs reduzir suas emissões de CO₂ em 37% e 43% nos anos de 2025 e 2030, respectivamente. Esses valores de redução propostos foram baseados nas emissões brasileiras de CO₂ em 2005 (342 Mt).

Neste estudo, realizamos duas análises de cenário. Em cada um desses cenários, alteramos as contribuições dos recursos energéticos no FTEP brasileiro e o indicador de queimadas na floresta amazônica. No primeiro cenário, consideramos que até 2030 o Brasil reduzirá 30% da oferta de energia a partir de gás natural, petróleo e carvão. Essa redução foi somada à oferta de energia a partir de recursos renováveis. Essa adição foi feita para manter o equilíbrio do sistema energético brasileiro.

Além disso, propusemos que até 2030 os incêndios na Floresta Amazônica serão reduzidos em pelo menos 70%. Para o segundo cenário, a oferta de energia a partir de combustíveis fósseis foi reduzida em 90%. Assim como antes, essa redução também foi adicionada aos recursos de energia renovável. Acreditamos também, que os incêndios na Floresta Amazônica serão reduzidos em 90%, já que o governo

brasileiro pretende eliminar o desmatamento ilegal no país, um dos maiores responsáveis pelos incêndios. A Figura 20 apresenta as previsões para as emissões brasileiras de CO₂ de acordo com as tendências de cada indicador estudado e as previsões obtidas nos dois cenários analisados.




Figura 20. Tendência normal das emissões brasileiras de CO₂ e previsões para os cenários analisados, entre 2019 – 2030. 1º Cenário: Substituição parcial dos recursos fósseis pelos renováveis em 30% e redução das queimadas nos biomas brasileiros em 70%. 2º Cenário: Substituição parcial dos recursos fósseis pelos renováveis em 90% e redução das queimadas nos biomas brasileiros em 90%.

Ao analisar a Figura 20, notamos que a opção pelo primeiro cenário analisado emitirá 471,35 Mt de CO₂ em 2030. Este valor corresponde a um decréscimo de 13,58% em relação ao caso (545,39 Mt) em que não houve alterações para favorecer o consumo de fontes renováveis de energia e nem para reduzir os incêndios na Floresta Amazônica. No segundo cenário, a emissão de CO₂ será de 390,24 Mt, o que corresponde a um decréscimo de 28,45% em relação à tendência normal. Esses resultados mostram que a substituição de recursos energéticos fósseis por renováveis não reduziu as emissões brasileiras de CO₂ na mesma proporção. No segundo cenário, por exemplo, a substituição foi de 90%, além da redução da queima em 90%. No entanto, mesmo nessas condições, a redução das emissões brasileiras de dióxido de carbono foi de 28,45%. Assim, tanto o combate a incêndios nos biomas brasileiros quanto a maior participação de recursos renováveis em sua matriz energética são elementos críticos para a redução das emissões de dióxido de carbono. Portanto, para que a redução dessas emissões seja mais

expressiva, o Brasil também precisa investir na eficiência de sua estrutura energética (LUCON; GOLDEMBERG, 2009).

A partir desses resultados, fica claro que o Brasil ainda não está no caminho certo para cumprir o Acordo de Paris. No entanto, é preciso considerar que o valor de referência (2005) utilizado no Acordo de Paris não é favorável. Em 2005, a população brasileira, o setor industrial do país e seu consumo de energia eram totalmente diferentes do que se vê hoje. Além disso, para que o país prospere nas esferas social e econômica, o desenvolvimento industrial é essencial, consumindo mais energia e emitindo mais CO₂. Portanto, o desafio do Brasil é encontrar estratégias e recursos energéticos que abasteçam satisfatoriamente sua matriz energética e que causem o menor impacto nas emissões de CO₂. Para tanto, o modelo de RNA neste trabalho se apresenta como uma ferramenta útil para propor e testar novas configurações na matriz energética brasileira a fim de conciliar desenvolvimento econômico com responsabilidade ambiental. Isso porque nossa RNA permite a alteração quantitativa dos indicadores de matriz energéticos brasileiros. Com essas mudanças, será possível saber o quanto elas impactarão, em termos quantitativos, as emissões brasileiras de CO₂. Ressaltamos, que essas mudanças nos indicadores da matriz energética brasileira e das queimadas nos biomas brasileiros para a análise de seus impactos quantitativos nas emissões brasileiras de CO₂, ainda não são encontradas na literatura. No entanto, esse conhecimento é fundamental para o Brasil e também para outros países, pois permite a substituição dos recursos energéticos que mais afetam a emissão de CO₂ por aqueles que menos a afetam. Portanto, o modelo quantitativo de previsão de emissões de CO₂ acrescenta uma utilidade prática em relação aos modelos qualitativos apresentados na literatura. Com o modelo proposto no presente estudo, vários cenários podem ser analisados a partir da relação quantitativa entre os indicadores de um país e suas emissões de dióxido de carbono. Com base nessas análises, os governos federais desenvolverão políticas que reduzam suas emissões de CO₂ a partir do melhor uso de seus recursos energéticos. Desta forma, as políticas energéticas podem trabalhar para a sustentabilidade econômica sem prejudicar o desenvolvimento econômico.

5. CONCLUSÃO

A partir da necessidade em se diminuir as emissões de dióxido de carbono para a manutenção da temperatura média global, nesse estudo, nós modelamos Redes Neurais Artificiais com intuito de prever as emissões brasileiras entre os anos de 2019 e 2030. Apesar da literatura apresentar modelos preditivos para as emissões brasileiras de dióxido de carbono, a maior parte dos estudos encontrados foram baseados em séries temporais, isto é, avaliaram as tendências das emissões a partir dos dados históricos dessas emissões por ano. Ainda que esses modelos tenham contribuído para o entendimento da tendência das emissões brasileiras de dióxido de carbono, eles são limitados, uma vez que não permitem mudanças em indicadores energéticos-ambientais do Brasil, a fim de propor medidas quantitativas para o controle dessas emissões. Os poucos trabalhos encontrados que avaliaram as emissões de dióxido de carbono a partir de indicadores do país ao invés de uma série temporal, ainda que tenham avançado na contribuição científica a esse tema, também não propuseram modificações quantitativas nesses indicadores nem nas políticas energéticas do Brasil.

Levando em consideração que o Brasil se comprometeu com o Acordo de Paris (2015) a reduzir suas emissões de dióxido de carbono em 43% até o ano de 2030, tendo como base o ano de 2005 (342 Mt), fica claro que ainda existe um longo caminho para que o país atinja esse objetivo. Sendo assim, a literatura ainda carece de modelos preditivos para as emissões brasileiras de CO₂ que permitam alterações nas variáveis independentes de forma a mostrar quantitativamente como essas alterações podem ajudar o Brasil na redução das suas emissões de dióxido de carbono.

Com base em nossos resultados, concluímos que a nossa Rede Neural Artificial (FFBP 3) foi capaz de aprender as relações existentes entre as emissões brasileiras de CO₂ e as entradas da rede utilizadas nesse estudo. Isso porque, o erro médio quadrático encontrado para a FFBP 3 foi de $4,92 \times 10^{-5}$.

A partir do MIV, ficou claro que os indicadores de recursos fósseis e de queimadas nos biomas brasileiros ocuparam posições acima das fontes renováveis em relação

às suas influências nas emissões de CO₂. Portanto, concluímos que a redução das queimadas e a maior utilização das fontes renováveis em detrimento das fósseis, apresentam-se como estratégia importante para a redução das emissões brasileiras de dióxido de carbono.

Também, analisamos nesse estudo dois cenários com mudanças nos indicadores da matriz energética brasileira e nos focos de queimada na Amazônia e demais biomas brasileiros. Essas modificações tiveram como propósito identificar de modo quantitativo quais ações podem auxiliar o governo brasileiro a cumprir o Acordo de Paris (2015), contribuindo com a manutenção da temperatura média global e com a sua imagem frente às outras nações participantes do mesmo acordo. Em nosso primeiro cenário, foi proposto que até o ano de 2030 o Brasil reduziria em 70% os focos de queimadas em seus biomas e que até esse mesmo ano, o país conseguiria substituir 30% do fornecimento de energia a partir de recursos fósseis em recursos renováveis. Nessa análise, obtivemos uma emissão de 471,35 Mt de dióxido de carbono. Esse valor, representa uma diminuição de 13,58% em relação à situação em que não houve nenhuma intervenção do governo brasileiro nas tendências dos indicadores de sua matriz energética (545,39 Mt). No segundo cenário proposto, consideramos uma redução de até 90% dos focos de queimadas nos biomas brasileiros até 2030 e que até esse mesmo ano, 90% da contribuição energética dos combustíveis fósseis seria substituída por recursos renováveis. Nesse contexto, obtivemos uma emissão de 390,24 Mt de dióxido de carbono, o que corresponde a uma diminuição de 28,45% em relação à emissão na situação em que não houve interferência do governo brasileiro em nenhum indicador avaliado (545,39 Mt).

Em suma, esse estudo foi capaz de modelar uma Rede Neural Artificial com a arquitetura de MLP de Propagação Retrógrada, cujo erro médio quadrático foi de $4,92 \times 10^{-5}$. Aliado ao baixo erro encontrado, os valores preditos para as emissões de dióxido de carbono entre 2019 e 2030 estão de acordo com outro estudo presente na literatura. Além disso, nossos resultados provaram que modificações nas parcelas de contribuição dos recursos fósseis na matriz energética brasileira impactam de forma mais expressiva as emissões de dióxido de carbono, em relação às modificações na parcela de contribuição dos recursos renováveis. Portanto,

podemos afirmar que a RNA apresentada nesse estudo representa de forma satisfatória a emissão brasileira de dióxido de carbono, levando em consideração sua dependência com o complexo sistema energético do Brasil e com os focos de queimadas na Amazônia e demais biomas. Devido ao fato de que o valor predito para as emissões no ano de 2030, sem que houvesse modificações nas tendências dos indicadores avaliados, não atenderam o compromisso firmado no Acordo de Paris (2015), foi necessário a proposição do estudo de cenários para se obter estratégias que ajudassem o país a cumprir esse compromisso. Nesses cenários, avaliamos um cenário realista e outro otimista com a diminuição dos focos de queimadas e com a substituição de recursos energéticos fósseis pelos renováveis. Com isso, obtivemos uma diminuição significativa em relação às emissões de dióxido de carbono no ano de 2030, sendo elas de 13,58% e de 28,45%, para o primeiro e o segundo cenário, respectivamente. Desse modo, nosso trabalho contribui de forma significativa com a literatura, uma vez que prediz as emissões brasileiras de dióxido de carbono a partir de indicadores econômicos-ambientais e propõem modificações quantitativas nesses indicadores, a fim de avaliar seus impactos nas emissões de dióxido de carbono e, portanto, auxiliar as políticas energéticas brasileiras para que haja uma redução efetiva nessas emissões ao mesmo tempo que preserva o fornecimento de energia no país.

6. SUGESTÃO PARA TRABALHOS FUTUROS

As redes neurais artificiais utilizam um banco de dados para o seu aprendizado e assim prever com acuidade resultados futuros. Sendo assim, quanto maior for o conjunto de dados disponíveis para o treinamento de uma inteligência artificial, melhor será a qualidade das previsões. Desse modo, com o passar dos anos, o banco de dados utilizados nesse trabalho deve ser constantemente atualizado, a fim de que a rede neural atinja previsões cada vez mais precisas. Além disso, o trabalho foi feito para o Brasil, sendo que é possível fazer o mesmo estudo para vários países ou agrupamentos (como os continentes). Nesse sentido, seria possível prever as emissões globais de CO₂, além de avaliar quantitativamente as alterações na matriz energética global que podem contribuir para a redução das emissões de dióxido de carbono. Paralelamente, pode-se estudar mais variáveis que podem ser relevantes para as emissões de CO₂, tornando o modelo apresentado nesse trabalho mais robusto e abrangente (utilizando-o em um cenário global ao invés de um nacional).

REFERÊNCIAS

ABE, J.; AJENIFUJA, E.; POPOOLA, O. Hydrogen energy, economy and storage: review and recommendation. *International Journal of Hydrogen Energy*, Elsevier, 2019.

ABOKYI, E. et al. Industrial growth and emissions of co₂ in ghana: the role of financial development and fossil fuel consumption. *Energy Reports*, Elsevier, v. 5, p. 1339–1353, 2019.

ACHEAMPONG, A. O.; BOATENG, E. B. Modelling carbon emission intensity: Application of artificial neural network. *Journal of Cleaner Production*, Elsevier, v. 225, p. 833–856, 2019.

AFOLABI, A. T. F.; LI, C.-Z.; KECHAGIOPOULOS, P. N. Microkinetic modelling and reaction pathway analysis of the steam reforming of ethanol over ni/sio₂. *International Journal of Hydrogen Energy*, Elsevier, v. 44, n. 41, p. 22816–22830, 2019.

AHMED, S.; AHMED, K.; ISMAIL, M. Predictive analysis of co₂ emissions and the role of environmental technology, energy use and economic output: evidence from emerging economies. *Air Quality, Atmosphere & Health*, Springer, v. 13, n. 9, p. 1035–1044, 2020.

AKBARZADEH, M. A. et al. The association between exposure to air pollutants including pm₁₀, pm_{2.5}, ozone, carbon monoxide, sulfur dioxide, and nitrogen dioxide concentration and the relative risk of developing stemi: A case-crossover design. *Environmental research*, Elsevier, v. 161, p. 299–303, 2018.

ALBERINI, A. et al. Preferences for energy efficiency vs. renewables: what is the willingness to pay to reduce co₂ emissions? *Ecological Economics*, Elsevier, v. 144, p. 171–185, 2018.

ALIMUJIANG, A.; JIANG, P. Synergy and co-benefits of reducing co₂ and air pollutant emissions by promoting electric vehicles—a case of shanghai. *Energy for Sustainable Development*, Elsevier, v. 55, p. 181–189, 2020.

ALMER, C.; WINKLER, R. Analyzing the effectiveness of international environmental policies: The case of the kyoto protocol. *Journal of Environmental Economics and Management*, Elsevier, v. 82, p. 125–151, 2017.

AMIN, S. Backpropagation–artificial neural network (bp-ann): Understanding gender characteristics of older driver accidents in west midlands of united kingdom. *Safety science*, Elsevier, v. 122, p. 104539, 2020.

ANDERSON, J. A. *An introduction to neural networks*. [S.I.]: MIT press, 1995.

ANDRADE, C. E. S. d.; D'AGOSTO, M. D. A. The role of rail transit systems in reducing energy and carbon dioxide emissions: The case of the city of rio de janeiro. *Sustainability*, Multidisciplinary Digital Publishing Institute, v. 8, n. 2, p. 150, 2016.

ANDREAE, M. O. Emission of trace gases and aerosols from biomass burning—an updated assessment. *Atmospheric Chemistry and Physics*, Copernicus GmbH, v. 19, n. 13, p. 8523–8546, 2019.

ANDREONI, V. The energy metabolism of countries: Energy efficiency and use in the period that followed the global financial crisis. *Energy Policy*, Elsevier, v. 139, p. 111304, 2020.

ARMAROLI, N.; BALZANI, V. The hydrogen issue. *ChemSusChem*, Wiley OnlineLibrary, v. 4, n. 1, p. 21–36, 2011.

AYODELE, T.; MUNDA, J. Potential and economic viability of green hydrogen production by water electrolysis using wind energy resources in south africa. *International Journal of Hydrogen Energy*, Elsevier, v. 44, n. 33, p. 17669–17687, 2019.

BÄCKSTRAND, K.; LÖVBRAND, E. The road to paris: Contending climate governance discourses in the post-copenhagen era. *Journal of Environmental Policy & Planning*, Taylor & Francis, v. 21, n. 5, p. 519–532, 2019.

BAIARDI, D. Do sustainable energy policies matter for reducing air pollution? *EnergyPolicy*, Elsevier, v. 140, p. 111364, 2020.

BAMBER, J. L. et al. Ice sheet contributions to future sea-level rise from structured expert judgment. *Proceedings of the National Academy of Sciences*, National AcadSciences, v. 116, n. 23, p. 11195–11200, 2019.

BANERJEE, S. G. et al. *Regulatory Indicators for Sustainable Energy*. [S.I.], 2017.

BANK, W. *Doing business 2019: Training for reform*. [S.I.]: World Bank Washington, USA, 2019.

BAO, C.; XU, M. Cause and effect of renewable energy consumption on urbanization and economic growth in china's provinces and regions. *Journal of cleaner production*, Elsevier, v. 231, p. 483–493, 2019.

BAO, H. et al. Effects of corn straw on dissipation of polycyclic aromatic hydrocarbons and potential application of backpropagation artificial neural network prediction model for pahs bioremediation. *Ecotoxicology and environmental safety*, Elsevier, v. 186, p.109745, 2019.

BAUER, A.; MENRAD, K. Standing up for the paris agreement: Do global climate targets influence individuals' greenhouse gas emissions? *Environmental Science & Policy*, Elsevier, v. 99, p. 72–79, 2019.

BEST, R.; TRÜCK, S. Capital and policy impacts on australian small-scale solar installations. *Energy Policy*, Elsevier, v. 136, p. 111082, 2020.

BILDIRICI, M. Impact of militarization and economic growth on biofuels consumption and co2 emissions: The evidence from brazil, china, and us. *Environmental Progress & Sustainable Energy*, Wiley Online Library, v. 37, n. 3, p. 1121–1131, 2018.

BLANCO, G. et al. Drivers, trends and mitigation. Cambridge University Press, 2014.

MINISTÉRIO DE MINAS E ENERGIA DO BRASIL. Termo de referência para elaboração do pne 2050. 2013.

MINISTÉRIO DE MINAS E ENERGIA DO BRASIL. Cenários de demanda para o pne 2050. 2018a.

MINISTÉRIO DE MINAS E ENERGIA DO BRASIL. Cenários econômicos para o pne 2050. 2018b.

MINISTÉRIO DE MINAS E ENERGIA DO BRASIL. Premissas e custos da oferta de energia elétrica no horizonte de 2050. 2018c.

Brazil Energy Information System. *Brazil energy data*. 2021. <https://www.mme.gov.br/SIEBRASIL/consultas/sistema-numerico.aspx?ss=2>. Accessed 18 August.

BRETSCHGER, L. Climate policy and economic growth. *Resource and Energy Economics*, Elsevier, v. 49, p. 1–15, 2017.

BRIESE, E. et al. Ecological network analysis of solar photovoltaic power generation systems. *Journal of cleaner production*, Elsevier, v. 223, p. 368–378, 2019.

BUDUMA, N.; LOCASCIO, N. *Fundamentals of deep learning: Designing next-generation machine intelligence algorithms*. [S.l.]: "O'Reilly Media, Inc.", 2017.

BULUT, U.; MENEGAKI, A. Solar energy-economic growth nexus in top 10 countries with the highest installed capacity. *Energy Sources, Part B: Economics, Planning, and Policy*, Taylor & Francis, v. 15, n. 5, p. 297–310, 2020.

CAO, J. et al. Increasing temperature sensitivity caused by climate warming, evidence from northeastern china. *Dendrochronologia*, Elsevier, v. 51, p. 101–111, 2018.

CAPIZZI, G. et al. Cascade feed forward neural network-based model for air pollutants evaluation of single monitoring stations in urban areas. *International Journal of Electronics and Telecommunications*, v. 61, n. 4, p. 327–332, 2015.

CARVALHO, K.; WANG, S. Characterizing the indian ocean sea level changes and potential coastal flooding impacts under global warming. *Journal of hydrology*, Elsevier, v. 569, p. 373–386, 2019.

CESARONI, G. et al. Long term exposure to ambient air pollution and incidence of acute coronary events: prospective cohort study and meta-analysis in 11 european cohorts from the escape project. *Bmj*, British Medical Journal Publishing Group, v. 348, p. f7412, 2014.

CHEN, B.; JUNGSTEDT, E. Fast and large-converge-radius inverse compositional levenberg–marquardt algorithm for digital image correlation: principle, validation, and open-source toolbox. *Optics and Lasers in Engineering*, Elsevier, v. 151, p. 106930, 2022.

CHEN, C.; PINAR, M.; STENGOS, T. Renewable energy consumption and economic growth nexus: Evidence from a threshold model. *Energy Policy*, Elsevier, v. 139, p. 111295, 2020.

CHEN, Y. et al. Large hydrological processes changes in the transboundary rivers of central asia. *Journal of Geophysical Research: Atmospheres*, Wiley Online Library, v. 123, n. 10, p. 5059–5069, 2018.

CHEN, Y.; ZHANG, Z.; TAO, F. Impacts of climate change and climate extremes on major crops productivity in china at a global warming of 1.5 and 2.0° c. *Earth System Dynamics (Online)*, Lawrence Berkeley National Laboratory (LBNL), Berkeley, CA (United States . . . , v. 9, n. 2, 2018.

CHIDAMBARANATHAN, B. et al. The production of biodiesel from castor oil as a potential feedstock and its usage in compression ignition engine: A comprehensive review. *Materials Today: Proceedings*, Elsevier, 2020.

CHO, Y.-H.; SHAYGAN, A.; DAIM, T. U. Energy technology adoption: Case of solar photovoltaic in the pacific northwest usa. *Sustainable Energy Technologies and Assessments*, Elsevier, v. 34, p. 187–199, 2019.

CONTINI, D.; VECCHI, R.; VIANA, M. *Carbonaceous aerosols in the atmosphere*. [S.l.]: Multidisciplinary Digital Publishing Institute, 2018.

CSEREKLYEI, Z.; QU, S.; ANCEV, T. The effect of wind and solar power generation on wholesale electricity prices in australia. *Energy Policy*, Elsevier, v. 131, p. 358–369, 2019.

DAMON, W. et al. *Handbook of child psychology, cognition, perception, and language*. [S.l.]: John Wiley & Sons, 2006.

DELL, R. M.; MOSELEY, P. T.; RAND, D. A. *Towards sustainable road transport*. [S.l.]: Academic Press, 2014.

DESHPANDE, V.; MODI, P.; SANT, A. V. Analysis of levenberg marquardt-ann based reference current generation for control of shunt active power filter. *Materials Today: Proceedings*, Elsevier, 2022.

DOGAN, E. The relationship between economic growth and electricity consumption from renewable and non-renewable sources: A study of turkey. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 52, p. 534–546, 2015.

EL-KARIMI, M. Economic growth and non-renewable and renewable energy consumption nexus in morocco: causality analysis in var model. *International Journal of Sustainable Economy*, Inderscience Publishers (IEL), v. 14, n. 2, p. 111–131, 2022.

FAHIM, M. A.; AL-SAHHAF, T. A.; ELKILANI, A. S. Introdução ao refino de petróleo.

Elsevier. Rio de Janeiro—RJ, 2012.

FAYE, B. et al. Impacts of 1.5 versus 2.0 c on cereal yields in the west african sudan savanna. *Environmental Research Letters*, IOP Publishing, v. 13, n. 3, p. 034014, 2018.

FAYED, M. et al. The ability of forecasting flapping frequency of flexible filament by artificial neural network. *Alexandria Engineering Journal*, Elsevier, 2019.

FILHO, R. I. da R. L.; AQUINO, T. C. N. de; NETO, A. M. N. Fuel price control in brazil: environmental impacts. *Environment, Development and Sustainability*, Springer, p. 1–16, 2020.

FISCHER, G. et al. Socio-economic and climate change impacts on agriculture: an integrated assessment, 1990–2080. *Philosophical Transactions of the Royal Society B: Biological Sciences*, The Royal Society London, v. 360, n. 1463, p. 2067–2083, 2005.

FOOD; ORGANIZATION, A. *Subnutrição Mundial em 2017*. 2018. Disponível em: <https://nacoesunidas.org/fao-fome-aumenta-no-mundo-e-afeta-821-milhoes-de-pessoas>.

FU, Z.; HAN, B.; CHEN, Y. Levenberg–marquardt method with general convex penalty for nonlinear inverse problems. *Journal of Computational and Applied Mathematics*, Elsevier, v. 404, p. 113771, 2022.

GARCIA, M. D. et al. Effects of glacier melting on the planktonic communities of two antarctic coastal areas (potter cove and hope bay) in summer. *Regional Studies in Marine Science*, Elsevier, v. 30, p. 100731, 2019.

GARRIDO-PEREZ, J. M. et al. Impact of weather regimes on wind power variability in western europe. *Applied Energy*, Elsevier, v. 264, p. 114731, 2020.

GASPAR, J. dos S.; MARQUES, A. C.; FUINHAS, J. A. The traditional energy-growth nexus: A comparison between sustainable development and economic growth approaches. *Ecological Indicators*, Elsevier, v. 75, p. 286–296, 2017.

GAUPP, F. et al. Increasing risks of multiple breadbasket failure under 1.5 and 2° cglobal warming. *Agricultural Systems*, Elsevier, v. 175, p. 34–45, 2019.

GHOLAMI, F. et al. Technologies for the nitrogen oxides reduction from flue gas: Areview. *Science of The Total Environment*, Elsevier, p. 136712, 2020.

Global Carbon Atlas. *Brazilian CO₂ emissions*. 2021. <http://www.globalcarbonatlas.org/en/CO2-emissions>. Acessed on 18 August.

Global Carbon Atlas. *Brazilian CO₂ emissions*. 2025. <https://globalcarbonatlas.org/emissions/carbon-emissions/>Accessed on 27 January.

GOMES, M. S. de S. et al. Proposal of a methodology to use offshore wind energy on the southeast coast of brazil. *Energy*, Elsevier, v. 185, p. 327–336, 2019.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.I.]: MIT press, 2016.

GRUNEWALD, N.; MARTINEZ-ZARZOSO, I. Did the kyoto protocol fail? an evaluation of the effect of the kyoto protocol on co 2 emissions. *Environment andDevelopment Economics*, Cambridge University Press, v. 21, n. 1, p. 1–22, 2016.

GURNEY, K. *An introduction to neural networks*. [S.I.]: CRC press, 1997.

HALKOS, G. E.; POLEMIS, M. L. The impact of economic growth on environmental efficiency of the electricity sector: A hybrid window dea methodology for the usa.

Journal of environmental management, Elsevier, v. 211, p. 334–346, 2018.

HAN, W. et al. Utilization of waste cake for fermentative ethanol production. *Science ofthe total environment*, Elsevier, v. 673, p. 378–383, 2019.

HAYKIN, S. *A Comprehensive Foundation: Neural Networks*. [S.I.]: Prentice Hall UpperSaddle River, 1999.

HENG, Y. et al. The heterogeneous preferences for solar energy policies among ushouseholds. *Energy Policy*, Elsevier, v. 137, p. 111187, 2020.

HERBERT, G. J.; KRISHNAN, A. U. Quantifying environmental performance of biomass energy. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 59, p. 292–308, 2016.

HERRERA, M. M.; DYNER, I.; COSENZ, F. Assessing the effect of transmission constraints on wind power expansion in northeast brazil. *Utilities Policy*, Elsevier, v. 59, p. 100924, 2019.

HEYDARI, A. et al. Renewable energies generation and carbon dioxide emission forecasting in microgrids and national grids using grnn-gwo methodology. *Energy Procedia*, Elsevier, v. 159, p. 154–159, 2019.

HUANG, J. et al. Methodology for the assessment and classification of regional vulnerability to natural hazards in china: the application of a dea model. *Natural Hazards*, Springer, v. 65, n. 1, p. 115–134, 2013.

INTERNATIONALENERGYAGENCY. *World Energy Outlook 2018, Paris*. Disponível em: <https://www.iea.org/reports/world-energy-outlook-2018>. Acesso em: 13 Abril.

2020.

ISSANOVA, G. et al. Saline soils and identification of salt accumulation provinces in kazakhstan. *Arid ecosystems*, Springer, v. 7, n. 4, p. 243–250, 2017.

IVANOVSKI, K.; HAILEMARIAM, A.; SMYTH, R. The effect of renewable and non-renewable energy consumption on economic growth: Non-parametric evidence. *Journal of Cleaner Production*, Elsevier, v. 286, p. 124956, 2021.

JOHNSTONE, N.; HAŠČIČ, I.; POPP, D. Renewable energy policies and technological innovation: evidence based on patent counts. *Environmental and resource economics*, Springer, v. 45, n. 1, p. 133–155, 2010.

KHASHMAN, A.; KHASHMAN, Z.; MAMMADLI, S. Arbitration of turkish agricultural policy impact on co2 emission levels using neural networks. *Procedia Computer Science*, Elsevier, v. 102, p. 583–587, 2016.

KHATUA, A.; JANA, S.; KAR, T. K. A fuzzy rule-based model to assess the effects of global warming, pollution and harvesting on the production of hilsa fishes. *Ecological Informatics*, Elsevier, v. 57, p. 101070, 2020.

KINLEY, R. Climate change after paris: from turning point to transformation. *ClimatePolicy*, Taylor & Francis, v. 17, n. 1, p. 9–15, 2017.

KÖNE, A. Ç.; BÜKE, T. Forecasting of co2 emissions from fuel combustion using trend analysis. *Renewable and Sustainable Energy Reviews*, Elsevier, v. 14, n. 9, p. 2906–2915, 2010.

LECUN, Y. et al. Gradient-based learning applied to document recognition. *Proceedings of the IEEE*, IEEE, v. 86, n. 11, p. 2278–2324, 1998.

LEO, S. D. et al. Regression analysis for energy demand projection: An application to times-basilicata and times-italy energy models. *Energy*, Elsevier, v. 196, p. 117058, 2020.

LI, Z. et al. Agricultural water demands in central asia under 1.5° c and 2.0° c global warming. *Agricultural Water Management*, Elsevier, v. 231, p. 106020, 2020.

LIN, B.; LUAN, R. Are government subsidies effective in improving innovation efficiency? based on the research of china's wind power industry. *Science of The Total Environment*, Elsevier, v. 710, p. 136339, 2020.

LINS, L. M.; ARBIX, G. Educação, qualificação, produtividade e crescimento econômico: a harmonia colocada em questão. *IPEA: Anais do I Círculo de Debates Acadêmicos*, 2011.

LIU, G. et al. Research advances towards large-scale solar hydrogen production from water. *EnergyChem*, Elsevier, p. 100014, 2019.

LIU, Y. et al. Impacts of 1.5 and 2.0° c global warming on rice production across china.

Agricultural and Forest Meteorology, Elsevier, v. 284, p. 107900, 2020.

LIVERMORE, M. A.; REVESZ, R. L. Environmental law and economics. *Oxford Handbook of Law and Economics*. Oxford University Press (Forthcoming), 2014.

LUCON, O.; GOLDEMBERG, J. Crise financeira, energia e sustentabilidade no brasil.

Estudos avançados, SciELO Brasil, v. 23, p. 121–130, 2009.

LYON, C. Complexity ethics and unfccc practices for 1.5 c climate change. *Current Opinion in Environmental Sustainability*, Elsevier, v. 31, p. 48–55, 2018.

MAAMOUN, N. The kyoto protocol: Empirical evidence of a hidden success. *Journal of Environmental Economics and Management*, Elsevier, v. 95, p. 227–256, 2019.

MAH, A. X. Y. et al. Review of hydrogen economy in malaysia and its way forward.

International Journal of Hydrogen Energy, Elsevier, 2019.

MAHALINGAM, B.; ORMAN, W. H. Gdp and energy consumption: A panel analysis of the us. *Applied Energy*, Elsevier, v. 213, p. 208–218, 2018.

MAHMOOD, T.; AHMAD, E. The relationship of energy intensity with economic growth: Evidence for european economies. *Energy strategy reviews*, Elsevier, v. 20, p. 90–98, 2018.

MASON, K.; DUGGAN, J.; HOWLEY, E. Forecasting energy demand, wind generation and carbon dioxide emissions in ireland using evolutionary neural networks. *Energy*, Elsevier, v. 155, p. 705–720, 2018.

MATSUNAGA, V. Y. Curso de redes neurais utilizando o matlab. *Belém do Pará*, 2012.

MENET, F. et al. Spartan networks: Self-feature-squeezing neural networks for increased robustness in adversarial settings. *Computers & Security*, Elsevier, v. 88, p. 101537, 2020.

MERINO-SAUM, A. et al. Articulating natural resources and sustainable development goals through green economy indicators: A systematic analysis. *Resources, Conservation and Recycling*, Elsevier, v. 139, p. 90–103, 2018.

MICHALSKI, J.; POLTRUM, M.; BÜNGER, U. The role of renewable fuel supply in the transport sector in a future decarbonized energy system. *International Journal of Hydrogen Energy*, Elsevier, v. 44, n. 25, p. 12554–12565, 2019.

MITCHELL, D. et al. Half a degree additional warming, prognosis and projected impacts (happi): background and experimental design. *Geoscientific Model Development*, EGU, v. 10, p. 571–583, 2017.

MIYAMOTO, M.; TAKEUCHI, K. Climate agreement and technology diffusion: Impact of the kyoto protocol on international patent applications for renewable energy technologies. *Energy policy*, Elsevier, v. 129, p. 1331–1338, 2019.

MLODINOW, L. *Subliminal: How your unconscious mind rules your behavior*. [S.l.]: Vintage, 2013.

MOREAU, V.; VUILLE, F. Decoupling energy use and economic growth: Counter evidence from structural effects and embodied energy in trade. *Applied energy*, Elsevier, v. 215, p. 54–62, 2018.

MOUNIR, E.-K.; EL-HOUJJAJI, H. Economic growth and renewable energy consumption nexus in g7 countries: Symmetric and asymmetric causality analysis infrequency domain. *Journal of Cleaner Production*, Elsevier, v. 342, p. 130618, 2022.

MOUNTCASTLE, V. B. Modality and topographic properties of single neurons of cat's somatic sensory cortex. *Journal of neurophysiology*, v. 20, n. 4, p. 408–434, 1957.

MUNASINGHE, S. P. et al. Prediction of chemical composition for callus production in *Gyrinops walla gaetner* through machine learning. *Information Processing in Agriculture*, Elsevier, 2019.

MUNJAL, N. et al. A constitutive expression system for cellulase secretion in *Escherichia coli* and its use in bioethanol production. *PloS one*, Public Library of Science, v. 10, n. 3, 2015.

MURITALA, I. K. et al. High temperature production of hydrogen: Assessment of non-renewable resources technologies and emerging trends. *International Journal of Hydrogen Energy*, Elsevier, 2019.

MUTHAYYA, S. et al. An overview of global rice production, supply, trade, and consumption. *Annals of the New York Academy of Sciences*, v. 1324, n. 1, p. 7–14, 2014.

NAIR, V.; HINTON, G. E. Rectified linear units improve restricted Boltzmann machines. In: *Proceedings of the 27th international conference on machine learning (ICML-10)*. [S.l.: s.n.], 2010. p. 807–814.

NATIONS, U. Paris agreement. In: *Framework Convention on Climate Change*. United Nations. [S.l.: s.n.], 2016.

NEGRI, F. D. Inovação e produtividade: por uma renovada agenda de políticas públicas. Instituto de Pesquisa Econômica Aplicada (Ipea), 2015.

DOZIĆ, D. J.; UROŠEVIĆ, B. D. G. Application of artificial neural networks for testing long-term energy policy targets. *Energy*, Elsevier, v. 174, p. 488–496, 2019.

PANEIRO, G.; RAFAEL, M. Artificial neural network with a cross-validation approach to blast-induced ground vibration propagation modeling. *Underground Space*, Elsevier, 2020.

PAO, H.-T.; CHEN, C.-C. Decoupling strategies: Co₂ emissions, energy resources, and economic growth in the group of twenty. *Journal of cleaner production*, Elsevier, v. 206, p. 907–919, 2019.

PAO, H.-T.; TSAI, C.-M. Modeling and forecasting the co₂ emissions, energy consumption, and economic growth in brazil. *Energy*, Elsevier, v. 36, n. 5, p. 2450–2458, 2011.

PARRY, M. L. et al. Effects of climate change on global food production under sres emissions and socio-economic scenarios. *Global environmental change*, Elsevier, v. 14, n. 1, p. 53–67, 2004.

PINO-MEJÍAS, R. et al. Comparison of linear regression and artificial neural networks models to predict heating and cooling energy demand, energy consumption and co₂ emissions. *Energy*, Elsevier, v. 118, p. 24–36, 2017.

PIRJOLA, L. et al. Potential of renewable fuel to reduce diesel exhaust particle emissions. *Applied Energy*, Elsevier, v. 254, p. 113636, 2019.

PIRMORADI, S. et al. The self-organizing restricted boltzmann machine for deep representation with the application on classification problems. *Expert Systems with Applications*, Elsevier, v. 149, p. 113286, 2020.

POZNYAK, A.; CHAIREZ, I.; POZNYAK, T. A survey on artificial neural networks application for identification and control in environmental engineering: Biological and chemical systems with uncertain models. *Annual Reviews in Control*, Elsevier, 2019.

PRIMC, K.; SLABE-ERKER, R. Social policy or energy policy? time to reconsider energy poverty policies. *Energy for Sustainable Development*, Elsevier, v. 55, p. 32–36, 2020.

RAJAMANI, L. The 2015 paris agreement: Interplay between hard, soft and non-obligations. *Journal of Environmental Law*, Oxford University Press, v. 28, n. 2, p. 337–358, 2016.

RAUBER, T. W. Redes neurais artificiais. *Universidade Federal do Espírito Santo*, p. 29, 2005.

REMPEL, E. L.; SILVA, F. Reconhecimento de padrões invariante a rotação utilizando uma rede neural morfológica não supervisionada. In: *V Congresso Brasileiro de Redes Neurais*. [S.l.: s.n.], 2001. p. 109–112.

REN, F.-r. et al. Analysis of co2 emission reduction contribution and efficiency of china's solar photovoltaic industry: Based on input-output perspective. *Energy*, Elsevier, p.

117493, 2020.

REN, X. et al. Challenges towards hydrogen economy in china. *International Journal of Hydrogen Energy*, Elsevier, 2020.

REQUIA, W. J. et al. Spatiotemporal analysis of traffic emissions in over 5000 municipal districts in brazil. *Journal of the Air & Waste Management Association*, Taylor & Francis, v. 66, n. 12, p. 1284–1293, 2016.

REŞİTOĞLU, İ. A. Nox pollutants from diesel vehicles and trends in the control technologies. In: *Diesel and Gasoline Engines*. [S.l.]: IntechOpen, 2018.

RESTAK, R. *The Secret Life of the Brain*, Joseph Henry. [S.l.]: National Academy Press) and Dana Press, Washington DC, 2001.

ROJAS-DELGADO, J.; TRUJILLO-RASÚA, R.; BELLO, R. A continuation approach for training artificial neural networks with meta-heuristics. *Pattern Recognition Letters*, Elsevier, v. 125, p. 373–380, 2019.

RUANE, A. C.; PHILLIPS, M. M.; ROSENZWEIG, C. Climate shifts within major agricultural seasons for+ 1.5 and+ 2.0 c worlds: HapPI projections and agMIP modeling scenarios. *Agricultural and forest meteorology*, Elsevier, v. 259, p. 329–344, 2018.

RUMELHART, D. E.; HINTON, G. E.; WILLIAMS, R. J. Learning representations by back-propagating errors cognitive modeling. *Nature* 1986b, p. 533–536, 1988.

SADEGHIANPOURHAMAMI, N. et al. Modeling and analysis of residential flexibility: Timing of white good usage. *Applied energy*, Elsevier, v. 179, p. 790–805, 2016.

SAHA, B. C. et al. Enhancement of xylose utilization from corn stover by a recombinant escherichia coli strain for ethanol production. *Bioresource technology*, Elsevier, v. 190, p.182–188, 2015.

SAINI, M. et al. Synthetic consortium of escherichia coli for n-butanol production by fermentation of the glucose–xylose mixture. *Journal of agricultural and food chemistry*, ACS Publications, v. 65, n. 46, p. 10040–10047, 2017.

SALMA, I. et al. Source apportionment of carbonaceous chemical species to fossil fuel combustion, biomass burning and biogenic emissions by a coupled radiocarbon-levoglucosan marker method. *Atmospheric Chemistry and Physics*, v. 17, n. 22, p. 13767–13781, 2017.

SANGEETHA, A.; AMUDHA, T. A novel bio-inspired framework for co2 emissionforecast in india. *Procedia Computer Science*, Elsevier, v. 125, p. 367–375, 2018.

SCHLEUSSNER, C.-F. et al. Crop productivity changes in 1.5 c and 2 c worlds under climate sensitivity uncertainty. *Environmental Research Letters*, IOP Publishing, v. 13, n. 6, p. 064007, 2018.

SCHULZ, J. R. da S.; RUPPENTHAL, J. E. Aplicação da metodologia de box & jenkins para análise das emissões de dióxido de carbono no brasil. *REUNIR: Revista de Administração, Contabilidade e Sustentabilidade*, v. 8, n. 3, 2018.

SCHWAB, K. The global competitiveness report 2018. In: *World Economic Forum*. [S.l.:s.n.], 2018. p. 9–14.

SHCHEKLEIN, S.; DUBININ, A. Analysis of nitrogen oxide emissions from modern vehicles using hydrogen or other natural and synthetic fuels in combustion chamber. *International Journal of Hydrogen Energy*, Elsevier, v. 45, n. 1, p. 1151–1157, 2020.

SIMMONS, W.; SEAKINS, P. Estimations of primary nitrogen dioxide exhaust emissions from chemiluminescence nox measurements in a uk road tunnel. *Science of the total environment*, Elsevier, v. 438, p. 248–259, 2012.

SINGH, D. et al. A review on feedstocks, production processes, and yield for different generations of biodiesel. *Fuel*, Elsevier, p. 116553, 2019.

SINIGAGLIA, T. et al. Use of patents as a tool to map the technological development involving the hydrogen economy. *World Patent Information*, Elsevier, v. 56, p. 1–8, 2019.

SMITH, P. et al. Agriculture, forestry and other land use (afolu). In: *Climate change 2014: mitigation of climate change. Contribution of Working Group III to the Fifth Assessment Report of the Intergovernmental Panel on Climate Change*. [S.l.]: Cambridge University Press, 2014. p. 811–922.

SMOLOVIĆ, J. C. et al. How does renewable energy consumption affect economic growth in the traditional and new member states of the european union? *Energy Reports*, Elsevier, v. 6, p. 505–513, 2020.

SONG, M. et al. Better resource management: An improved resource and environmental efficiency evaluation approach that considers undesirable outputs. *Resources, Conservation and Recycling*, Elsevier, v. 128, p. 197–205, 2018.

SOW, A. et al. Economic analysis of residential solar photovoltaic electricity production in canada. *Sustainable Energy Technologies and Assessments*, Elsevier, v. 33, p. 83–94, 2019.

STOCKER, T. F. et al. Climate change 2013: The physical science basis. *Contribution of working group I to the fifth assessment report of the intergovernmental panel on climate change*, Cambridge university press Cambridge New York, v. 1535, 2013.

STOFFEL, M. et al. Artificial neural networks in structural dynamics: A new modular radial basis function approach vs. convolutional and feedforward topologies. *Computer Methods in Applied Mechanics and Engineering*, Elsevier, v. 364, p. 112989, 2020.

SUN, X. et al. Synthesis of chemicals by metabolic engineering of microbes. *Chemical society reviews*, Royal Society of Chemistry, v. 44, n. 11, p. 3760–3785, 2015.

TAGHAVIFAR, H. et al. Appraisal of artificial neural networks to the emission analysis and prediction of co₂, soot, and nox of n-heptane fueled engine. *Journal of cleaner production*, Elsevier, v. 112, p. 1729–1739, 2016.

TAN, X.; JI, Z.; ZHANG, Y. Non-invasive continuous blood pressure measurement based on mean impact value method, bp neural network, and genetic algorithm. *Technology and Health Care*, IOS Press, v. 26, n. S1, p. 87–101, 2018.

TANG, Y.; GU, X.; CHEN, G. 99% yield biodiesel production from rapeseed oil using benzyl bromide–cao catalyst. *Environmental chemistry letters*, Springer, v. 11, n. 2, p. 203–208, 2013.

THOMPSON, P. R. et al. Forcing of recent decadal variability in the equatorial and north indian ocean. *Journal of Geophysical Research: Oceans*, Wiley Online Library, v. 121, n. 9, p. 6762–6778, 2016.

TOBIN, P. et al. Mapping states' paris climate pledges: Analysing targets and groups at cop 21. *Global environmental change*, Elsevier, v. 48, p. 11–21, 2018.

TOLLIVER, C.; KEELEY, A. R.; MANAGI, S. Drivers of green bond market growth: The importance of nationally determined contributions to the paris agreement and implications for sustainability. *Journal of Cleaner Production*, Elsevier, v. 244, p. 118643, 2020.

TORABI, N. et al. Progress and challenges in perovskite photovoltaics from single-to multi-junction cells. *Materials Today Energy*, Elsevier, v. 12, p. 70–94, 2019.

TRUETTNER, C. et al. Conifer radial growth response to recent seasonal warming and drought from the southwestern USA. *Forest ecology and management*, Elsevier, v. 418, p.55–62, 2018.

TUNA, G.; TUNA, V. E. The asymmetric causal relationship between renewable and non-renewable energy consumption and economic growth in the asean-5 countries.

Resources Policy, Elsevier, v. 62, p. 114–124, 2019.

TURKI, I. et al. Effects of global climate oscillations on intermonthly to interannual variability of sea levels along the english channel coasts (nw france). *Oceanologia*, Elsevier, 2020.

UNITED NATIONS CLIMATE CHANGE. *Conferência das Partes*. Acessado em 29 de Junho de 2020. Disponível em: (<https://unfccc.int/about-us/about-the-secretariat>).

VÉLEZ-FORT, M. et al. A circuit for integration of head-and visual-motion signals in layer 6 of mouse primary visual cortex. *Neuron*, Elsevier, v. 98, n. 1, p. 179–191, 2018.

VELOSO, F.; BONELLI, R.; CASTELAR, A. *Anatomia da Produtividade no Brasil*. [S.l.]: Elsevier Brasil, 2017.

VERHELST, S. et al. Methanol as a fuel for internal combustion engines. *Progress in Energy and Combustion Science*, Elsevier, v. 70, p. 43–88, 2019.

VERSCHUUREN, J. The paris agreement on climate change: Agriculture and food security. *European Journal of Risk Regulation*, Cambridge University Press, v. 7, n. 1, p.54–57, 2016.

VITA, A. et al. Steam reforming, partial oxidation, and autothermal reforming of ethanol for hydrogen production in conventional reactors. In: *Ethanol*. [S.l.]: Elsevier, 2019. p. 159–191.

WANG, Y. et al. Precipitation forecast of the wujiang river basin based on artificial bee colony algorithm and backpropagation neural network. *Alexandria Engineering Journal*, Elsevier, 2020.

WEI, D. et al. Influences of nitrogen oxides and isoprene on ozone-temperature relationships in the amazon rain forest. *Atmospheric environment*, Elsevier, v. 206, p.280–292, 2019.

WOO, K. S. et al. Glacial melting pulses in the antarctica: Evidence for different responses to regional effects of global warming recorded in antarctic bivalve shell (*laternula elliptica*). *Journal of Marine Systems*, Elsevier, v. 197, p. 103179, 2019.

World Bank. *Brazil data*. 2021. <https://developers.google.com/transit/gtfs/?hl=pt-br>. Accessed 18 August.

WU, W. et al. A novel conformable fractional non-homogeneous grey model for forecasting carbon dioxide emissions of brics countries. *Science of the Total Environment*, Elsevier, v. 707, p. 135447, 2020.

XU, G.; SCHWARZ, P.; YANG, H. Determining china's co2 emissions peak with a dynamic nonlinear artificial neural network approach and scenario analysis. *Energy policy*, Elsevier, v. 128, p. 752–762, 2019.

YAN, C. et al. Characterization of carbon fractions in carbonaceous aerosols from typical fossil fuel combustion sources. *Fuel*, Elsevier, v. 254, p. 115620, 2019.

YANG, J. et al. Understanding the material efficiency of the wind power sector in china: A spatial-temporal assessment. *Resources, Conservation and Recycling*, Elsevier, v. 155, p. 104668, 2020.

YASMEEN, S. et al. Contrasting climate-growth relationship between *larix gmelinii* and *pinus sylvestris* var. *mongolica* along a latitudinal gradient in daxing'an mountains, china. *Dendrochronologia*, Elsevier, v. 58, p. 125645, 2019.

YU, W. et al. Predictive control of co₂ emissions from a grate boiler based on fuel nature structures using intelligent neural network and box-behnken design. *Energy Procedia*, Elsevier, v. 158, p. 364–369, 2019.

ZHANG, W.; ZHOU, T. Increasing impacts from extreme precipitation on population over china with global warming. *Science Bulletin*, Elsevier, v. 65, n. 3, p. 243–252, 2020.

ZHANG, X. et al. The impacts of wind technology advancement on future global energy.

Applied energy, Elsevier, v. 184, p. 1033–1037, 2016.

ZHAO, C.; ZHANG, Y.; LI, Y. Production of fuels and chemicals from renewable resources using engineered escherichia coli. *Biotechnology advances*, Elsevier, 2019.

ZHOU, T. et al. Extreme rainfall event in the context of a longer-term drying tendency. 2012.

ZHOU, Y. et al. Mechanism of co₂ emission reduction by global energy interconnection.

Global Energy Interconnection, Elsevier, v. 1, n. 4, p. 409–419, 2018.

APÊNDICE A

Tabela 1. Dados reais de partida utilizados na modelagem das Redes Neurais Artificiais.

	PIB (USDD)	População	FTEP	CE	Fontes Renováveis	Gás Natural	Produtos Petrolíferos	CM	Queimadas
1998	863.723.411.633	169.785.250	138.259	26.405	74.798	10.712	50.215	2.080	123.321
1999	599.388.579.986	172.318.675	146.752	27.155	75.452	11.815	56.723	2.130	134.604
2000	655.420.645.477	174.790.340	153.388	28.534	72.720	13.190	63.754	2.614	101.514
2001	559.372.276.082	177.196.054	156.267	26.637	71.875	13.900	66.567	2.185	145.484
2002	507.962.487.700	179.537.520	174.250	27.895	77.468	15.416	74.927	1.999	321.414
2003	558.319.920.832	181.809.246	183.732	29.430	85.116	15.681	77.225	1.823	340.739
2004	669.316.654.017	184.006.481	190.228	30.955	89.878	16.852	76.641	2.153	380.445
2005	891.630.177.251	186.127.103	200.523	32.267	93.656	17.575	84.300	2.483	362.566
2006	1.107.640.289.615	188.167.356	211.786	33.536	99.150	17.582	89.214	2.287	248.984
2007	1.397.084.349.956	190.130.443	223.653	35.443	107.522	18.025	90.765	2.349	393.914
2008	1.695.824.565.983	192.030.362	236.453	36.829	113.292	21.398	94.000	2.653	211.933
2009	1.667.019.783.585	193.886.508	240.419	36.638	111.079	20.983	100.918	2.080	155.104
2010	2.208.871.646.203	195.713.635	253.108	39.964	118.831	22.771	106.559	2.104	319.286
2011	2.616.200.980.392	197.514.534	256.434	41.363	115.901	23.888	108.976	2.134	158.102
2012	2.465.188.674.415	199.287.296	257.035	42.861	116.462	25.574	107.258	2.517	217.238
2013	2.472.806.919.902	201.035.903	258.211	44.373	118.215	27.969	104.762	3.298	128.149
2014	2.455.993.625.159	202.763.735	272.708	45.782	118.788	31.661	116.705	3.059	175.900
2015	1.802.214.373.741	204.471.769	286.375	45.110	120.579	34.871	126.127	2.459	216.782
2016	1.795.700.168.991	206.163.058	294.796	44.838	122.256	37.610	130.373	2.636	182.218
2017	2.062.831.045.936	207.833.831	303.024	45.413	123.546	39.810	135.907	1.931	207.511
2018	1.885.482.534.238	209.469.333	308.074	46.303	129.669	40.560	134.067	1.930	132.872

* As unidades de medida dos indicadores energéticos estão em 10³ tep (tonelada equivalente de petróleo), a de População em habitantes e a de Queimadas em número de focos.

APÊNDICE B

As alterações das combinações dos números de neurônios foram feitas manualmente nos códigos das redes modeladas.

Código para a Rede Neural Artificial (*Feed Forward Back Propagation 3*):

```
set(0,'defaultfigurecolor',[1 1 1])

input = [0.16875    0.04337    0.06994    0.02439    0.00000    0.02389    0.07654
         0.18198    0.28444    0.42174    0.56344    0.54978    0.80679    1.00000
         0.92837    0.93198    0.92401    0.61390    0.61081    0.73752    0.65340
0.00000    0.06384    0.12612    0.18674    0.24575    0.30299    0.35836
         0.41180    0.46321    0.51268    0.56056    0.60733    0.65337    0.69875
         0.74342    0.78749    0.83103    0.87407    0.91669    0.95879    1.00000
0.00000    0.05001    0.08909    0.10604    0.21194    0.26778    0.30603
         0.36666    0.43298    0.50286    0.57824    0.60159    0.67632    0.69590
         0.69944    0.70637    0.79174    0.87222    0.92181    0.97026    1.00000
0.00000    0.03770    0.10703    0.01166    0.07492    0.15206    0.22870
         0.29460    0.35838    0.45425    0.52391    0.51432    0.68145    0.75177
         0.82705    0.90303    0.97382    0.94008    0.92641    0.95531    1.00000
0.05056    0.06188    0.01462    0.00000    0.09677    0.22910    0.31150
         0.37687    0.47193    0.61679    0.71663    0.67834    0.81248    0.76178
         0.77148    0.80181    0.81173    0.84273    0.87173    0.89406    1.00000
0.00000    0.03693    0.08301    0.10679    0.15760    0.16648    0.20570
         0.22993    0.23016    0.24498    0.35802    0.34410    0.40401    0.44144
         0.49791    0.57815    0.70185    0.80941    0.90118    0.97487    1.00000
0.00000    0.07595    0.15800    0.19083    0.28838    0.31520    0.30839
         0.39776    0.45511    0.47321    0.51096    0.59169    0.65752    0.68573
         0.66568    0.63655    0.77592    0.88587    0.93543    1.00000    0.97854
0.17429    0.20823    0.53603    0.24539    0.11924    0.00000    0.22371
         0.44756    0.31456    0.35679    0.56267    0.17414    0.19086    0.21076
         0.47066    1.00000    0.83781    0.43091    0.55102    0.07305    0.07258
0.07458    0.11317    0.00000    0.15038    0.75205    0.81814    0.95394
         0.89279    0.50434    1.00000    0.37763    0.18328    0.74477    0.19353
         0.39577    0.09109    0.25440    0.39421    0.27601    0.36251    0.10724
];

target = [0.00000    0.03700    0.07387    0.11449    0.08873    0.04269    0.11768
          0.15669    0.15604    0.22549    0.33415    0.24020    0.47746    0.56429
          0.70409    0.86619    1.00000    0.86697    0.67670    0.72144    0.69060
];

% for i=0:1:100 função para variar o rng
rng (26)

net = feedforwardnet([7 6]); % criação da rede, camadas e neurônios

net.divideFcn= 'dividerand'; % função para divisão dos dados
net.divideParam.trainRatio= 0.65; % para o treinamento
net.divideParam.valRatio= 0.175; % para a validação
net.divideParam.testRatio= 0.175; % para o teste
net.divideParam % conferir as porcentagens escolhidas

[net,tr] = train(net,input,target);
plotperform(tr);
end
```

Código para a Rede Neural Artificial (*Cascade Feed Back Propagation 1*):

```
set(0,'defaultfigurecolor',[1 1 1])
```

```
input = [0.16875    0.04337    0.06994    0.02439    0.00000    0.02389    0.07654
         0.18198    0.28444    0.42174    0.56344    0.54978    0.80679    1.00000
         0.92837    0.93198    0.92401    0.61390    0.61081    0.73752    0.65340
0.00000    0.06384    0.12612    0.18674    0.24575    0.30299    0.35836
         0.41180    0.46321    0.51268    0.56056    0.60733    0.65337    0.69875
         0.74342    0.78749    0.83103    0.87407    0.91669    0.95879    1.00000
0.00000    0.05001    0.08909    0.10604    0.21194    0.26778    0.30603
         0.36666    0.43298    0.50286    0.57824    0.60159    0.67632    0.69590
         0.69944    0.70637    0.79174    0.87222    0.92181    0.97026    1.00000
0.00000    0.03770    0.10703    0.01166    0.07492    0.15206    0.22870
         0.29460    0.35838    0.45425    0.52391    0.51432    0.68145    0.75177
         0.82705    0.90303    0.97382    0.94008    0.92641    0.95531    1.00000
0.05056    0.06188    0.01462    0.00000    0.09677    0.22910    0.31150
         0.37687    0.47193    0.61679    0.71663    0.67834    0.81248    0.76178
         0.77148    0.80181    0.81173    0.84273    0.87173    0.89406    1.00000
0.00000    0.03693    0.08301    0.10679    0.15760    0.16648    0.20570
         0.22993    0.23016    0.24498    0.35802    0.34410    0.40401    0.44144
         0.49791    0.57815    0.70185    0.80941    0.90118    0.97487    1.00000
0.00000    0.07595    0.15800    0.19083    0.28838    0.31520    0.30839
         0.39776    0.45511    0.47321    0.51096    0.59169    0.65752    0.68573
         0.66568    0.63655    0.77592    0.88587    0.93543    1.00000    0.97854
0.17429    0.20823    0.53603    0.24539    0.11924    0.00000    0.22371
         0.44756    0.31456    0.35679    0.56267    0.17414    0.19086    0.21076
         0.47066    1.00000    0.83781    0.43091    0.55102    0.07305    0.07258
0.07458    0.11317    0.00000    0.15038    0.75205    0.81814    0.95394
         0.89279    0.50434    1.00000    0.37763    0.18328    0.74477    0.19353
         0.39577    0.09109    0.25440    0.39421    0.27601    0.36251    0.10724
];
```

```
target = [0.00000    0.03700    0.07387    0.11449    0.08873    0.04269    0.11768
          0.15669    0.15604    0.22549    0.33415    0.24020    0.47746    0.56429
          0.70409    0.86619    1.00000    0.86697    0.67670    0.72144    0.69060
];
```

```
% for i=0:1:100 função para variar o rng
rng (183)
```

```
net = cascadeforwardnet([4 10]); % criação da rede, camadas e neurônios
net = train(net,input,target);
[net,tr] = train(net,input,target);
plotperform(tr);
end
```

APÊNDICE C

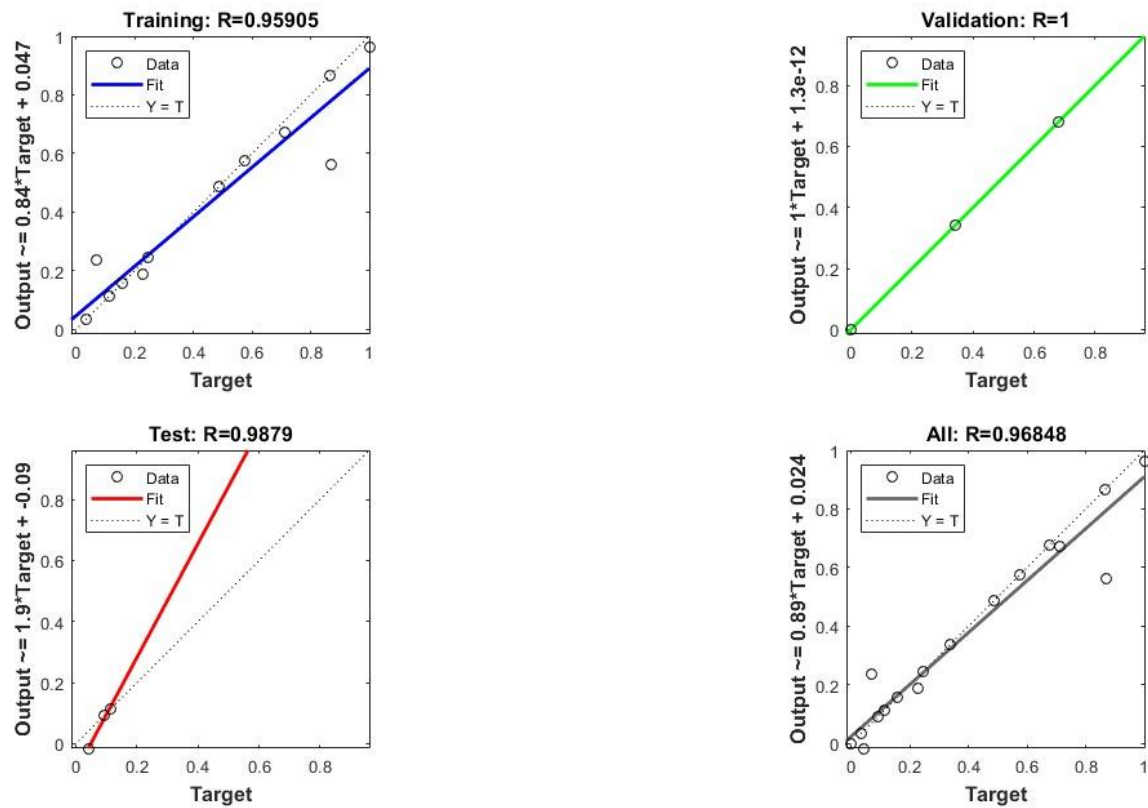


Figura 1. Teste de performance da RNA gerado pelo Matlab para a FFBP 3.

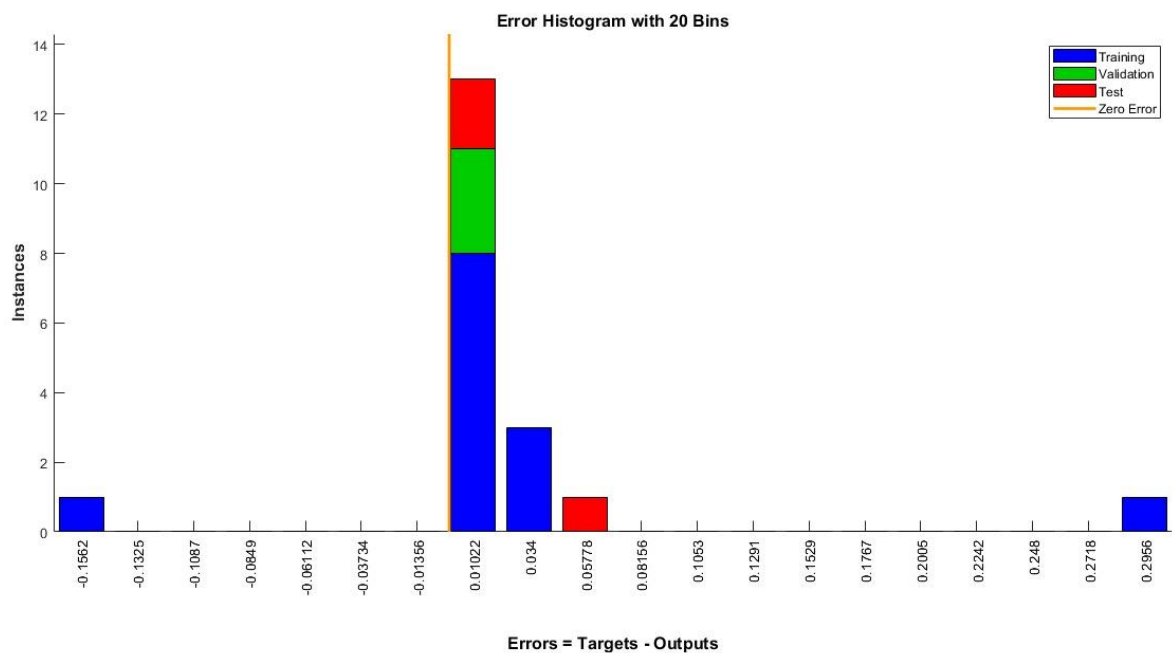


Figura 2. Histograma de erros obtidos para a FFBP3 gerado pelo Matlab para a FFBP 3.




Figura 3. Avaliação da etapa de validação da FFBP 3 gerada pelo Matlab.




Figura 4. Avaliação de performance da FFBP 3 a partir do erro médio quadrático para as etapas de treinamento, validação e teste, gerada pelo Matlab.