



Latin American Journal of Energy Research – Lajer (2025) v. 12, n. 4, p. 83–96
<https://doi.org/10.21712/lajer.2025.v12.n4.p83-96>

Análise das emissões de carbono no Brasil por meio de redes neurais artificiais: uma investigação sobre processos industriais
Analysis of carbon emissions in Brazil using artificial neural networks: an investigation into industrial processes

Carlos Roberto Souza Carmo¹, Murilo Miceno Frigo^{2,*}, Fernando de Lima Caneppele³

¹ Professor na Universidade Federal de Uberlândia

² Professor do Instituto Federal de Educação Ciência e Tecnologia de Mato Grosso do Sul

³ Professor na Universidade de São Paulo

*Autor para correspondência, E-mail: murilo.frigo@ifms.edu.br

Received: 28 November 2025 | Accepted: 24 December 2025 | Published online: 24 December 2025

Resumo: Diante da necessidade do desenvolvimento de políticas públicas mais efetivas na mitigação das emissões de gases de efeito estufa e da tomada de decisões voltadas ao planejamento estratégico em setores chave da economia, como energia, indústria e agricultura, entre outros, visando a sustentabilidade ambiental, esta investigação teve por objetivo avaliar como o processo de modelagem, previsão e simulação computacional, baseado em redes neurais artificiais, pode permitir aferir o impacto das alterações na matriz energética sobre as emissões de dióxido de carbono (CO₂) da indústria brasileira. Os resultados observados indicam que o processo de modelagem, previsão e simulação computacional, baseado em redes neurais artificiais, traz como desfecho primário a possibilidade de se avaliar objetivamente o impacto das alterações na matriz energética sobre as emissões de CO₂ da indústria brasileira. Como desfecho secundário, decorrente do processo de simulação em si, os resultados observados neste trabalho científico possibilitaram identificar aquelas fontes de energia cuja substituição por fontes alternativas consideradas limpas e renováveis, ainda que em pequenos percentuais (até 1%), permitiriam reduzir mais que proporcionalmente (até 10,30%) as emissões de CO₂ do segmento industrial brasileiro como um todo. Adicionalmente, os resultados observados sinalizaram que as substituições de combustíveis na matriz energética devem ser realizadas de maneira direcionada, ou ainda, de forma pontual e específica por tipo de combustível, uma vez que as reduções simultâneas em todos os combustíveis integrantes da matriz energética não foram tão expressivas quanto às reduções observadas em cenários cujas reduções percentuais foram propostas para uma só fonte.

Palavras-chave: sustentabilidade; mitigação; efeito estufa; métodos computacionais.

Abstract: Given the need for more effective public policies for mitigating greenhouse gas emissions and for decision making aimed at strategic planning in key economic sectors, such as energy, industry, and agriculture, among others, with a view to environmental sustainability, this investigation aimed to evaluate how the process of computational modeling, forecasting, and simulation based on artificial neural networks can allow the assessment of the impact of changes in the energy matrix on carbon dioxide emissions from the Brazilian industrial sector. The results observed indicate that the process of computational modeling, forecasting, and simulation based on artificial neural networks has as its primary outcome the possibility of objectively evaluating the impact of changes in the energy matrix on the CO₂ emissions of the Brazilian industrial sector. As a secondary outcome, resulting from the simulation process itself, the results observed in this scientific study made it possible to identify those energy sources whose replacement with alternative sources considered clean and renewable, even at small percentages up to 1 percent, would allow a more than proportional reduction up to 10.30 percent in CO₂ emissions from the Brazilian industrial segment as a whole. Additionally, the results observed indicated that fuel substitutions in the energy matrix should be carried out in a targeted manner, or in other words, specifically and individually by fuel type, since simultaneous reductions in all fuels that compose the energy matrix were not as significant as the reductions observed in scenarios in which percentage reductions were proposed for only one source.

Keywords: sustainability, mitigation, greenhouse effect, computational methods.

1 Introdução

Não é possível desassociar crescimento econômico, consumo energético e emissões de carbono (CO₂) da preservação ambiental requerida para que se possa chegar à sustentabilidade econômica em qualquer nível de análise, ou seja, regional, nacional ou global.

Nesse sentido, o Acordo de Paris de 2015 requer que as nações participantes empreendam ações voltadas para a limitação do aumento da temperatura global em 2° Celsius, comparativamente aos níveis observados nos períodos pré-industriais, com a indicação de que o limite desejado não ultrapasse 1,5° (Gupta; Davis; Kumar, 2021; Santos et al., 2024), o que passa necessariamente pelo desenvolvimento de políticas públicas mais efetivas na mitigação das emissões de gases de efeito estufa (GEE). Para tanto, é preciso reduzir drasticamente as emissões dos GEE provenientes das atividades humanas até 2050 (Löfgren e Rootzén, 2021), por exemplo, os gases como óxido nitroso (N₂O), metano (CH₄), ozônio (O₃), entre outros, com especial atenção para o dióxido de carbono (CO₂), produzido em maior quantidade em decorrência da queima de combustíveis fósseis para a produção energética.

Contudo, em virtude das tendências de crescimento econômico e elevação do consumo, o que se observa é a projeção de um aumento de 4° Celsius na temperatura global até 2100, o que desencadearia efeitos climáticos extremos e cada vez mais frequentes (Santos et al., 2021). E isso, por sua vez, reforça a necessidade de uma resposta global voltada à superação dos desafios impostos por tais alterações climáticas (CEBDS, 2017).

Ao considerar que os processos industriais são parte integrante do desenvolvimento econômico das nações, e ainda, que tais processos apresentam uma demanda energética constante - se não, crescente - as mudanças na composição das matrizes energéticas nacionais tornaram-se um tema de profunda relevância econômica, social e, principalmente, ambiental. Pois, diante da elevação nas demandas energéticas da população e, por consequência, o aumento das emissões dos GEE, torna-se imprescindível implementar ações voltadas para a redução do uso de combustíveis fósseis na geração de energia (Santos et al., 2024), assim como, é necessário desenvolver o planejamento estratégico em setores chave da economia, como energia, indústria e agricultura, entre outros, visando a sustentabilidade ambiental.

Dentre tais ações, destaca-se a busca pela utilização de fontes alternativas de energia, baseadas em recursos renováveis, contribuindo para redução da insegurança energética e das implicações adversas de natureza ambiental (Nibedita e Irfan, 2024). Mas, apesar do aumento na quantidade de investigações sobre o domínio das energias renováveis nos últimos anos (Santos et al., 2024), ainda é urgente buscar soluções voltadas para a mitigação das mudanças climáticas experimentadas ultimamente; e um dos meios para isso é a compreensão dos fatores que influenciam as emissões de GEE (Zambrano-Monserrate, 2024).

Todavia, esse tipo de solução encontra obstáculos em limitações relacionadas à capacidade econômico-financeira e restrições institucionais próprias de contextos específicos, bem como, nas características específicas de instalações industriais (IPCC, 2018). E, do ponto de vista das respostas comportamentais ao nível da demanda energética, a troca de combustíveis em setores como construção, transporte e, em especial, na indústria, pode contribuir significativamente para a redução das emissões de CO₂ (IPCC, 2018).

Nesse contexto, esta investigação foi conduzida a partir do seguinte questionamento direcionador: como o processo de modelagem, previsão e simulação computacional, baseado em redes neurais artificiais (RNA), pode permitir avaliar o impacto das alterações na matriz energética sobre as emissões de CO₂ da indústria brasileira? Para responder essa questão de pesquisa, inicialmente, buscou-se conhecer a temática relacionada ao consumo de energia e os aspectos envolvendo as emissões de CO₂ da indústria, e ainda, as possíveis influências e consequências do processo de transição energética, conforme descrito no embasamento teórico do estudo científico ora relatado (seção 2). Adicionalmente, foi identificado e analisado o conjunto de variáveis referentes ao total das emissões de CO₂ geradas pela indústria brasileira como um todo, bem como, a composição relativa à sua matriz energética, e ainda, buscou-se identificar e aplicar métodos computacionais baseados em RNA que permitissem realizar previsões voltadas para a avaliação do impacto das alterações na matriz energética da indústria brasileira sobre as respectivas emissões de CO₂, conforme descrito na metodologia desta pesquisa (seção 3). Finalmente, com base na plataforma teórica constituída e no respectivo processo de análise de dados, procedeu-se à implementação dos modelos preditivos propostos com base em RNA buscando prever e analisar as emissões de CO₂ da indústria brasileira, diante de diferentes cenários de matriz energética (seção 4).

Ao considerar que a produção de energia é um dos fatores mais significativos para o aquecimento global, sendo responsável por mais de 60% das emissões mundiais de GEE (Ali et al., 2023), o processo de transição energética, de combustíveis fósseis para fontes renováveis e menos poluentes, pode contribuir significativamente para a mudança nas matrizes energéticas nacionais (Gupta et al., 2021). Assim, esta pesquisa se justifica pela possibilidade de fornecer subsídios à discussão relacionada à descarbonização no Brasil, uma vez que os modelos pesquisados podem ajudar a indústria a identificar e implementar matrizes energéticas que resultem em menores emissões de CO₂ e, por consequência, podem contribuir também para a pesquisa em mudanças climáticas, fornecendo ferramentas robustas para previsões mais confiáveis acerca das futuras emissões dos GEE.

2 Referencial teórico

É inegável o fato de que tanto as emissões dos GEE quanto a decorrente deterioração ambiental são um problema de nível global, cujas principais causas passam pela questão relacionada ao consumo de combustíveis fósseis (Veja et al., 2024). E, para manter a elevação da temperatura média global abaixo dos 2° Celsius, conforme proposto no Acordo de Paris, seria necessário um nível de emissões de CO₂ líquido próximo de zero até 2050. No entanto, a proposta das nações participantes do acordo para reduzir as emissões de GEE relacionadas à produção de energia, isto é, uma redução de 2/3 das emissões totais até 2030, está muito distante do necessário para se atingir tal média (Treut et al., 2021).

Essa realidade leva a uma relação conflituosa entre políticas públicas e soluções limitadas e incapazes de serem implantadas em escala suficiente para tirar o mundo da atual encruzilhada climática em que se encontra (Santos et al., 2021). Uma possível explicação para essa situação pode estar relacionada às soluções propostas pela literatura disponível sobre o tema. Ou seja, apesar da literatura relacionada a sistemas de energia e à mitigação dos efeitos climáticos por meio da redução drástica das emissões de GEE ser convergente acerca de soluções pautadas pela transição energética no sentido de uma matriz de baixo CO₂ (Felder e Kumar, 2021), ela contrasta, em grande parte, com a literatura econômica (Löfgren e Rootzén, 2021). Pois, enquanto a primeira preocupa-se com a descrição detalhada de modelos e seus atores, estruturas, processos e suas interações, à luz de uma perspectiva multinível e específica; a segunda está centrada nas mudanças proporcionadas pela inovação e pela tecnologia, distanciando-se do rigor de modelos detalhados, sendo voltada para resultados mais generalizáveis (Löfgren e Rootzén, 2021).

Dessa maneira, o detalhamento das modelagens descritas pelas pesquisas sobre sistemas de energia e mitigação dos efeitos climáticos leva à sua aplicação de forma específica e, conseqüentemente, com poucas condições de generalização. Ao contrário dessa corrente, esta investigação busca adicionar conhecimentos que passam por soluções baseadas no processo de transição energética, porém, devido à natureza das variáveis e aos métodos analíticos utilizados, identifica-se maior possibilidade de generalização analítica e diagnóstica. E isso pode ser de grande utilidade, já que, a despeito da necessidade de se enfrentar os problemas em questão, o processo de transição energética para fontes de baixa emissão de GEE tem sido lento (Miniard e Attari, 2021).

Uma possível solução para a necessidade de transição energética demandada atualmente implica na diversificação das matrizes energéticas nacionais que, além de historicamente proporcionar vantagens do ponto de vista econômico, permite uma mudança gradual para fontes sustentáveis de energia (Shahbaz et al., 2023). Pois, além de reduzir a dependência de uma única fonte, a diversificação do mix energético assegura uma transição mais estável para a economia (Shahbaz et al., 2023), tornando-se reconhecida como uma estratégia realista e acessível, tanto para economias desenvolvidas quanto para aquelas consideradas emergentes (Nibedita e Irfan, 2024).

A transição energética para sistemas produtivos de baixo carbono passa necessariamente por fatores econômicos, sociais, políticos e tecnológicos (Miniard e Attari, 2021). E, mesmo com a existência de casos em que a transição tecnológico-energética tenha ocorrido rapidamente (em alguns anos ou décadas), evidências empíricas sugerem que transições mais robustas podem levar muitas décadas, até séculos, o que tem dificultado tanto a difusão da tecnologia em si, quanto o próprio processo de redução das emissões de GEE, entre outros impactos negativos (Löfgren e Rootzén, 2021).

Ao viabilizar a produção de eletricidade de baixo carbono por meio da mudança das fontes de combustíveis utilizados para tanto, pode-se chegar a uma redução entre 70%-100% dos níveis das emissões “pré-industriais” até 2050 (Löfgren e Rootzén, 2021). E, um dos principais impulsionadores dessa transição é a eletrificação do sistema energético com base em fontes renováveis de energia, uma vez que esse é o setor cujas informações históricas permitem obter orientações para o futuro (Henderson e Sen, 2021). Ou seja, a produção de eletricidade baseada na diversificação das matrizes energéticas mundiais, levando-se

em conta o próprio histórico desse setor, pode ser o caminho mais viável para redução das emissões dos GEE.

Nesse sentido, apesar de apresentar uma das matrizes energéticas menos poluentes do mundo devido à intensa utilização dos seus recursos hidrelétricos, o Brasil é um dos maiores consumidores mundiais de energia (Veja et al., 2024). E, por isso, a geração de energia elétrica baseada em combustível fóssil ainda tem um papel significativo na matriz energética brasileira, o que pode se agravar ainda mais em função dos planos para a construção de novas usinas geradoras de eletricidade a partir de combustíveis fósseis para os próximos anos, a despeito da elevada participação da geração de energia baseada em recursos renováveis (Pelissari et al., 2023).

Apesar da sua matriz energética ser dominada pela energia hidrelétrica, seguida por fontes geradoras de eletricidade baseadas em biomassa e energia eólica (Lampis et al., 2022), entre outras, o Brasil responde por quase um terço das emissões de GEE da América Latina e Caribe, o que fez com que o país se propusesse a reduzir suas emissões em 37% até 2025 e 43% até 2030, comparativamente aos níveis observados em 2005 (CEBDS, 2017; Nadaleti et al., 2022), tomando como base o processo de transição energética para fontes renováveis de energia, inclusive com a expansão da participação de fontes não hídricas na sua matriz energética (Nadaleti; Souza; Souza, 2022), uma vez que, da forma como acontece no Brasil, a energia hidrelétrica também pode ser considerada uma fonte significativa de impactos sociais e ambientais, mesmo com a baixa emissão de GEE (Lampis et al., 2022).

Ao considerar que a composição econômica de uma nação guarda relação direta com seu desenvolvimento, e que o setor industrial é essencial para o crescimento da economia de uma maneira geral, e ainda, que esse setor é responsável por mais de um terço (35%) do consumo mundial de energia (Hamed et al., 2023), fica evidente que a descarbonização requer necessariamente maior compreensão acerca da oferta e da demanda de energia inerentes aos processos industriais, entre outros setores da economia (Felder e Kumar, 2021).

Especificamente no Brasil, a eletricidade, com uma participação média de 20,7% ano-1, e os subprodutos oriundos da cana-de-açúcar, com uma participação média de 19,4% ano-1, são as fontes de energia mais consumidas pelo setor industrial, segundo os dados da Empresa de Pesquisa Energética (EPE) brasileira (EPE, 2023). Sendo que, ainda segundo os dados da EPE (2024), a participação relativa das demais fontes energéticas nacionais não ultrapassa a média de 12% ano-1. Tal quadro sinaliza a existência de certa margem para a diversificação do mix energético utilizado pela indústria do Brasil, uma vez que se observa uma tendência de crescimento da média anual das emissões de CO₂, sinalizada principalmente desde o ano de 2017, com especial atenção ao total das emissões brasileiras de 2021 (107.948.487 t).

A substituição dos combustíveis fósseis por fontes e formas de energia de baixo carbono é fundamental para os processos de transição e diversificação em si; contudo, enquanto um processo de passagem de um estado para outro, essa transição demanda o declínio controlado do atual sistema energético-produtivo, cuja predominância é de combustíveis de natureza fóssil, (Henderson e Sen, 2021). Considerando que a energia é essencial ao desenvolvimento humano e econômico, bem como, o fato de que as várias alternativas de descarbonização propostas encontram obstáculos em, no mínimo, diferentes níveis de maturidade técnica e comercial, na heterogeneidade da distribuição geográfica, além de fatores como a sazonalidade produtiva dos recursos naturais e questões geopolíticas (Araújo et al., 2024), entre outros, deve-se levar em conta que a utilização de energias renováveis por si só, enquanto parâmetro indicador da solução do problema relacionado aos GEE, não é necessariamente preciso (Zambrano-Monserrate, 2024); o que torna imprescindível compreender os impactos da combinação de diversas fontes de energia nas matrizes energéticas das nações, conforme proposto nesta investigação, o que pode contribuir para a pesquisa em mudanças climáticas, fornecendo ferramentas robustas para previsões mais confiáveis das futuras emissões.

Para além das questões ambientais, a incorporação de fontes alternativas na matriz energética, no intuito de reduzir a concentração e dependência, evita a exposição econômica e social aos riscos de abastecimento, propicia o avanço tecnológico, reduz a importação de energia, entre outros (Shahbaz et al., 2023). Contudo, com o foco principal nas questões de natureza ambiental, a compreensão acerca de como o processo de modelagem, previsão e simulação computacional, baseado em RNA, pode permitir avaliar o impacto das alterações na matriz energética brasileira, com especial atenção às emissões de CO₂ da indústria nacional, fornecendo subsídios à discussão relacionada ao processo de descarbonização no Brasil, uma vez que os modelos ora pesquisados podem ajudar a indústria a identificar e implementar matrizes energéticas que resultem em menores emissões de CO₂.

3 Metodologia

Para o desenvolvimento do processo de modelagem, previsão e simulação computacional baseado em redes neurais artificiais (RNA), a fim de avaliar o impacto das alterações na matriz energética sobre emissões de CO₂ da indústria brasileira, foi composta uma base de dados formada, inicialmente, pelas observações referentes aos totais anuais das emissões CO₂, em toneladas (t), referente exclusivamente aos “processos industriais e uso de produtos” (IPPU) divulgados pelo Sistema de Registro Nacional de Emissões (SIRENE) do Ministério da Ciência, Tecnologia e Inovação brasileiro (Brasil, 2023), com base na métrica do Potencial de Aquecimento Global ou Global Warming Potential (GWP) do Quinto Relatório de Avaliação (AR5) do Intergovernmental Panel on Climate Change (IPCC), portanto CO₂-GWP-AR5.

A seguir, a base de dados desta pesquisa foi complementada com as informações referentes aos totais consumidos anualmente, em toneladas equivalentes de petróleo (tep), dos combustíveis utilizados como fontes de energia primária e secundária no Balanço Energético Nacional (BEN), segundo as séries históricas divulgadas pela EPE (2023). Sendo que, a partir desses valores totais, por tipo de combustível e total geral consumido pelo segmento de IPPU como um todo, foi calculada a participação relativa anual de cada fonte de combustível (% do total de consumido em tep) na matriz energética desse segmento econômico.

O período adotado para análise contemplou as observações anuais de 1990 até 2020, ou seja, 31 observações tanto para a variável dependente (CO₂-GWP-AR5) quanto para as suas possíveis variáveis explicativas (participação relativa dos combustíveis utilizados anualmente como fontes de energia primária e secundária descritas no BEM para o segmento de IPPU), caracterizando-se assim o conjunto dos dados integrantes da amostra desta pesquisa, cujo perfil seguiu o detalhamento descritivo resumido na Tabela 1.

Tabela 1 – Perfil da amostra de pesquisa, para um total de 31 observações ($n = 31$).

Variáveis	média	lim. inf.	lim. sup.	desvio	mediana	mínimo	máximo
CO ₂ -GWP-AR5 (t)	81.646.924	76.885.068	86.408.780	13.527.235	83.335.260	56.870.297	102.246.265
Petróleo (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Gás natural (%) ^a	8,04%	6,98%	9,09%	2,99%	9,36%	3,16%	11,36%
Carvão vapor (%) ^a	3,52%	3,25%	3,80%	0,79%	3,75%	1,94%	4,67%
Carvão metalúrgico (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Urânio U3O8 (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Energia hidráulica (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Lenha (%) ^a	8,93%	8,54%	9,33%	1,12%	8,80%	7,51%	12,38%
Produtos da cana (%) ^a	17,01%	15,86%	18,16%	3,27%	17,79%	10,28%	22,00%
Outras fontes primárias (%) ^a	6,22%	5,53%	6,90%	1,95%	5,87%	3,43%	10,26%
Biodiesel (%) ^a	0,03%	0,02%	0,05%	0,04%	0,00%	0,00%	0,14%
Óleo diesel (%) ^a	0,97%	0,91%	1,03%	0,17%	0,92%	0,68%	1,31%
Óleo combustível (%) ^a	8,21%	6,23%	10,18%	5,61%	6,09%	1,59%	16,62%
Gasolina (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
GLP (%) ^a	0,98%	0,88%	1,08%	0,29%	0,97%	0,37%	1,44%
Nafta energética (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Querosene (%) ^a	0,03%	0,02%	0,04%	0,04%	0,01%	0,00%	0,13%
Gás de cidade e de coqueira (%) ^a	1,58%	1,47%	1,68%	0,30%	1,46%	1,29%	2,21%
Coque de carvão mineral (%) ^a	10,21%	9,53%	10,90%	1,95%	9,57%	7,00%	13,88%
Urânio UO2 (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Eleticidade (%) ^a	20,87%	20,64%	21,10%	0,65%	20,78%	19,74%	22,26%
Carvão vegetal (%) ^a	6,63%	5,86%	7,41%	2,20%	6,69%	3,86%	12,48%
Álcool etílico anidro+hidr. (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Outras fontes secund.de petr. (%) ^a	6,62%	5,76%	7,48%	2,44%	7,68%	2,19%	9,09%
Produtos não energ de petr. (%) ^{a b}	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Alcatrão (%) ^a	0,16%	0,11%	0,20%	0,12%	0,11%	0,05%	0,47%

Legenda:

(a) participação relativa de cada fonte no total consumido pelo segmento de IPPU, segundo o Balanço Energético Nacional (EPE (2023), a partir da seguinte fórmula: participação relativa no total em % = [(consumo da fonte em 10³ tep / total em 10³ tep) 100];

(b) conforme pode ser observado pelas respectivas estatísticas descritivas, apesar de constarem na relação de combustíveis integrantes da matriz energética brasileira, segundo os dados da EPE (2023), as seguintes fontes energéticas não foram utilizadas pelo segmento DE IPPU para a geração de energia: petróleo; carvão metalúrgico; urânio U3O8; energia hidráulica; gasolina; nafta energética; urânio UO2; álcool etílico anidro-hidratado; produtos não energéticos de petróleo. Logo, não foram alvo de qualquer tipo de análise nesta investigação.

Levando-se em conta a quantidade de informações disponíveis, os principais desafios a serem superados neste estudo foram relacionados ao conjunto das informações disponíveis para composição da base de dados da pesquisa, bem como, o respectivo processo de modelagem preditiva e sua validação. Ou seja: acerca da disponibilidade de informações, destaca-se a limitação de apenas 31 observações anuais para a variável dependente (CO2-GWP-AR5), uma vez que o período de informações disponibilizado no SIRENE pelo Ministério da Ciência, Tecnologia e Inovação brasileiro (Brasil, 2023) compreendeu somente os anos de 1990 até 2020; em relação ao processo de modelagem preditiva e sua validação, deve-se observar que os modelos preditivos pesquisados a partir de machine learning (ML), baseados em redes neurais artificiais (RNA), demandam uma considerável quantidade de observações para treinamento e validação desse tipo de modelagem, sendo que, a ocorrência de problemas com *overfitting* é muito comum na aplicação desse tipo algoritmo em pequenos conjuntos de dados (Collins et al., 2021).

Mesmo diante dos avanços tecnológicos experimentados na análise preditiva em baseada em ML, entre outras técnicas, a cada dia são demandados volumes de dados cada vez maiores para que se consiga tirar maior proveito das técnicas de ML baseadas em RNA (Galaz et al., 2021). Pois, o tamanho da amostra de dados utilizada contribui para o melhor desempenho preditivo, uma vez que amostras pequenas podem resultar em estimativas superdimensionadas acerca do efeito dos parâmetros preditores (inputs ou valores de entrada), gerando problemas de *overfitting* (Collins et al., 2021).

O *overfitting* no treinamento de RNA do tipo *perceptron* multicamadas (MLP) é um problema especialmente sério (Murakoshi, 2005), uma vez que o modelo pesquisado se ajusta muito bem ao conjunto dos dados utilizados para treinamento, apresentando baixos erros de previsão; contudo, ao tentar realizar generalizações, o erro observado no conjunto dos dados utilizados para teste apresenta-se significativamente superior aos erros observados na fase de treinamento (Wang et al., 2023).

Para suprir essa limitação referente à quantidade de observações, foi utilizado o processo de reamostragem de *bootstrap*, que pode ser caracterizado como uma ferramenta útil na obtenção de dados necessários ao desenvolvimento de pesquisas cujas amostras sejam consideradas relativamente pequenas, o que poderia inviabilizar a produção do conhecimento científico (Carmo e Lima, 2018). O método de *bootstrap* é uma técnica de reamostragem que permite simular diversas amostras, a partir de um estimador desejado (Liu e Dai, 2023), sem que se assuma algum tipo de distribuição teórica específica (Efron, 1979). Para tanto, basta garantir que as amostras de *bootstrap* (reamostras) sejam geradas de maneira randomizada, e ainda, que elas tenham as mesmas características essenciais da respectiva amostra original (McRoberts et al., 2023), o que, no caso desta pesquisa, foi garantido ao gerar aleatoriamente *s* amostras de *bootstrap* que seguiram aquele perfil da amostra original (com 31 observações) descrito na Tabela 1.

Assim, depois de definida a amostra mestre desta pesquisa, que foi composta originalmente por 31 observações ($n=31$), foi implementado o método de reamostragem, mediante sorteio por randomização e reposição de dados, e foram geradas 6 amostras de *bootstrap* com quantidades de observações distintas, porém, todas com o mesmo perfil da amostra original descrito na Tabela 1. Dessa maneira, formou-se uma base de dados composta por 6 amostras de *bootstrap* com as seguintes quantidades de observações: “boot100” com 100 observações ($n=100$); “boot200” com 200 observações ($n=200$); “boot300” com 300 observações ($n=300$); e assim sucessivamente até a amostra de *bootstrap* final “boot600” com 600 observações ($n=600$).

Após a identificação da amostra original e das amostras *bootstrap*, foram implementados os processos de treinamento e teste de redes neurais artificiais do tipo *perceptron* de múltiplas camadas (RNA MLP). Sendo que, a implementação de cada uma daquelas RNA MLP teve por objetivo promover a aprendizagem sobre como os consumos anuais relativos dos combustíveis utilizados como fontes de energia primária e secundária descritas no BEN da indústria brasileira, segundo sua participação relativa, poderiam explicar os totais anuais das emissões de CO2 referentes às atividades de IPPU.

Para tanto, em todas as RNA MLP pesquisadas nesta investigação, 70% das observações de cada amostra (1 original e 6 amostras de *bootstrap*) foram utilizadas para treinamento, e 30% das observações foram utilizadas para testes acerca dos respectivos processos de aprendizagem. Em todas as RNA MLP, a camada de entrada contou com 16 variáveis explicativas (somente aquelas com percentuais diferentes de zero, já descritas na Tabela 1) padronizadas pelo método do escalonamento (mensuráveis em unidades quantitativas). Optou-se por 1 camada oculta com, no mínimo, 5 unidades *perceptron* cada, excluindo-se a unidade de viés, e ainda, com função de ativação pelo método da tangente hiperbólica. Na camada de saída, foi utilizada a padronização como método de reescalonamento das variáveis dependentes, função de ativação identidade e função de minimização do erro pela soma dos quadrados.

Para a análise de desempenho de cada uma das 7 RNA MLP implementadas a partir de conjuntos de dados com tamanhos amostrais diferentes (6 amostras de *bootstrap* com *n* diversos e 1 amostra original

com $n=31$ observações), foi utilizado um conjunto de métricas composto pelos seguintes indicadores quantitativos, cujas formas de cálculos, unidades de medida e parâmetros de decisão estão descritos na Tabela 2: coeficiente de determinação (R^2); o percentual da amostra não explicável pelas variáveis independentes ($[1-R^2]100$); o erro absoluto médio ou *mean absolut error* (MAE); o erro percentual médio absoluto ou *mean absolute percentage error* (MAPE); o erro percentual médio absoluto simétrico ou *symmetric mean absolute percentage error* (SMAPE); e, o erro percentual médio absoluto ponderado ou *weighted mean absolute percentage error* (WMAPE).

Diante das vantagens e limitações de cada uma das métricas utilizadas para avaliação do desempenho preditivo das RNA MLP pesquisadas, todas elas foram utilizadas de forma complementar entre si, segundo as equações descritas na Tabela 2. Esse conjunto de métricas de desempenho preditivo foi aplicado de forma comparativa, entre os processos de treinamento e teste, como um meio para identificar a possível ocorrência de *overfitting* nas RNA MLP implementadas nesta pesquisa, e ainda, para identificar aquela RNA de melhor desempenho preditivo, de tal forma que, a partir daquela com melhor desempenho, se pudesse realizar simulações acerca das possíveis alterações no total das emissões de CO₂-GWP-AR5 (variável dependente), em função de alterações no mix de fontes de combustíveis integrantes da matriz energética do segmento dos IPPU, na economia brasileira.

Tabela 2 – Relação das métricas de precisão utilizadas para avaliação de desempenho das RNA MLP.

Fórmula	Unidade de medida (un) e parâmetro de decisão
$R^2(y, \hat{y}) = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2}$	$0 < R^2 < 1$ sendo que, quanto mais próximo de 1 melhor
$MAE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n y_i - \hat{y}_i $	<i>un do MAE = un de y</i> sendo que: quanto menor melhor
$MAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{ y_i }$	$0 < MAPE < 1$ sendo que: quanto menor melhor
$MdAPE(y, \hat{y}) = \frac{ y_i - \hat{y}_i }{ y_i }$	$0 < MdAPE < 1$ sendo que: quanto menor melhor
$SMAPE(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n \frac{ y_i - \hat{y}_i }{(y_i + \hat{y}_i)/2}$	$0 < SMAPE < 1$ sendo que: quanto menor melhor
$WMAPE(y, \hat{y}) = \frac{\sum_{i=1}^n y_i - \hat{y}_i }{\sum_{i=1}^n y_i }$	$0 < WMAPE < 1$ sendo que: quanto menor melhor

Dessa maneira, tomando por base a participação relativa fontes de combustíveis integrantes da matriz energética do segmento dos IPPU na economia brasileira no ano de 2020, foram simulados 12 cenários ([C]) distintos ([C1], ...[C12]), nos quais, foram realizados incrementos simultâneos de 0,50% na participação daquelas duas fontes energéticas com maior participação relativa no BEN da indústria brasileira, também consideradas fontes limpas e renováveis de energia, ou seja, produtos da cana e eletricidade, e ainda, em cada cenário, foi simulada simultaneamente uma redução de 1,00% em cada uma das demais fontes energéticas utilizadas pelo segmento dos IPPU, ou seja: [C1] outras fontes primárias; [C2] lenha; [C3] gás natural; [C4] coque de carvão mineral; [C5] outras fontes secund. de petróleo; [C6] carvão vegetal; [C7] carvão vapor; [C8] óleo combustível; [C9] gás de cidade e de coqueira; [C10] GLP; e, [C11] óleo diesel; adicionalmente, foi simulado um cenário [C12] no qual foi simulada a redução de 0,10% em todas aquelas fontes já descritas (com incrementos simultâneos de 0,55% na participação daquelas duas fontes energéticas com maior participação relativa no BEN da indústria brasileira). Cabe observar que aquelas fontes energéticas cuja participação relativa no BEN da indústria brasileira de 2020 foi inferior a 1,00% não tiveram reduções simuladas nas respectivas participações, foram elas: o biodiesel, com uma participação relativa em 2020 de 0,141%; o alcatrão, com uma participação relativa em 2020 de 0,095%; e, o querosene, com uma participação relativa em 2020 de 0,001%.

Mediante a identificação e aplicação da RNA previsora com melhor avaliação de desempenho, foram estimados os respectivos totais (em t) de emissões de CO₂-GWP-AR5 (variável dependente) das atividades de IPPU, em cada um daqueles 12 cenários [C1, ...C12], identificando-se as respectivas variações (Δ) percentuais, comparativamente aos montantes (em t) observados em 2020. E, a partir daí, foram realizadas

análises à luz da possibilidade de desenvolvimento de políticas públicas mais efetivas na mitigação das emissões de gases de efeito estufa, do planejamento estratégico em setores chave da economia, como é o caso da indústria nacional, visando a sustentabilidade ambiental, e ainda, vislumbrando-se a possibilidade de se gerar contribuições voltadas para a pesquisa em mudanças climáticas, mediante o fornecimento de uma possível ferramenta robusta para previsões mais confiáveis de emissões futuras.

Diante do proceder metodológico ora exposto, esta pesquisa pode ser classificada como uma investigação de natureza empírica, baseada em métodos computacionais aplicados na análise de fenômenos de natureza ambiental influenciados pela composição da matriz energética nacional, ou ainda, do respectivo BEN.

4 Resultados e discussões

Ao aplicar o processo de reamostragem pelo método de *bootstrap* aos dados da amostra original desta pesquisa, portanto, aquela com 31 observações anuais para a variável de estudo e suas variáveis explicativas, foram geradas 6 amostras de bootstrap com quantidades totais de observações (n) distintas, e ainda, foram treinadas e testadas as respectivas RNA MLP, cujos resumos de desempenho estão descritos na Tabela 2.

Pôde-se observar que as RNA MLP (treinadas com 70% do n total e testadas com 30% do n total) com quantidades totais de observações (n) inferiores a 400 (Amostra original, Bot100, Bot200 e Bot300) apresentaram desempenhos distintos nos processos de treinamento e teste, o que pode ser considerado um indicador da presença de problemas relacionados a *overfitting* (Collins et al., 2021). E, conforme demonstrado na Tabela 3, para um n total entre 400 e 600 observações ($400 < n[\text{treinamento} + \text{teste}] < 600$) as métricas de desempenho apresentaram uma tendência de convergência, com especial atenção à RNA MLP que utilizou a amostra Bot400, que apresentou o melhor desempenho entre todas, cujas métricas avaliativas de desempenharam puderam ser consideradas as mais próximas.

Tabela 3 – Avaliação de desempenho das RNA MLP por amostra.

Amostra	Tipo	n	R ²	(1-R ²)100	MAE	MAPE	SMAPE	WMAPE
Amostra original	Treinamento	22	0,9919	0,81%	586.641	0,82%	0,82%	0,78%
	Teste	9	0,5384	46,16%	3.973.702	4,03%	4,15%	4,08%
Bot100	Treinamento	70	0,9990	0,10%	283.526	0,36%	0,36%	0,35%
	Teste	30	0,9399	6,01%	1.403.099	1,79%	1,86%	1,71%
Bot200	Treinamento	140	0,9990	0,10%	256.629	0,31%	0,31%	0,31%
	Teste	60	0,9990	0,10%	336.655	0,45%	0,45%	0,43%
Bot300	Treinamento	210	0,9991	0,09%	224.993	0,26%	0,26%	0,27%
	Teste	90	0,9990	0,10%	257.817	0,31%	0,31%	0,32%
Bot400	Treinamento	280	0,9990	0,10%	270.034	0,31%	0,31%	0,33%
	Teste	120	0,9987	0,13%	280.270	0,32%	0,32%	0,34%
Bot500	Treinamento	350	0,9991	0,09%	321.079	0,39%	0,39%	0,39%
	Teste	150	0,9987	0,13%	350.349	0,41%	0,41%	0,43%
Bot600	Treinamento	420	0,9991	0,09%	258.335	0,30%	0,30%	0,32%
	Teste	180	0,9988	0,12%	293.996	0,34%	0,34%	0,36%

Identificada aquela RNA MLP com melhor desempenho preditivo (Bot400) acerca da variável dependente em análise nesta investigação (total de CO₂-GWP-AR5 em t), foram realizadas simulações para composição cenários nos quais ocorreram incrementos simultâneos de 0,50% naquelas duas fontes energéticas com maior participação relativa no BEN da indústria brasileira (produtos da cana com participação de 21,997% e eletricidade com 20,759%), aqui consideradas fontes limpas e renováveis de energia. E ainda, em cada cenário, foi simulado simultaneamente uma redução de 1,00% nas demais fontes energéticas utilizadas pelo segmento dos IPPU, exceto aquelas cujas participações relativas eram inferiores a 1,00%, com base no BEN da indústria brasileira no ano de 2020, conforme detalhado na Tabela 4.

Adicionalmente, conforme pode ser constatado também na Tabela 3, foi simulado um cenário no qual promoveu-se um incremento simultâneo de 0,55% na participação daquelas duas fontes energéticas com maior participação relativa no BEN do segmento de IPPU da indústria brasileira, e ainda, uma redução simultânea de 0,10% em todas as demais fontes (11 fonte) com participação relativa superior a 1,00%, conforme demonstrado no cenário [C12] da Tabela 4.

Mediante a aplicação daquela RNA MLP de melhor desempenho preditivo, pesquisada anteriormente (ou seja, aquela gerada a partir da amostra de *bootstrap* Bot400), foram estimadas emissões totais de CO₂-

GWP-AR5 (em t) do segmento de IPPU e comparadas com os montantes observados efetivamente em 2020, identificando-se as respectivas variações (Δ) em termos relativos (%).

Conforme demonstrado na Tabela 2, a redução de 1% na participação relativa de fontes energéticas como GLP ($\Delta = -10,30\%$), óleo diesel ($\Delta = -9,88\%$) e carvão vapor ($\Delta = -6,86\%$) promoveria uma redução nas emissões de CO₂-GWP-AR5 do segmento de IPPU significativamente superior a 5%. E ainda, exceto pelo grupo das outras fontes primárias, qualquer redução de 1% das respectivas participações no BEN do segmento dos IPPU implicaria em uma redução mais que proporcional ($> 1,00\%$) no total das emissões de CO₂-GWP-AR5 do segmento econômico em análise.

Essa constatação pode ser caracterizada como uma evidência do potencial inexplorado para novas reduções nas emissões de GEE a partir de uso de medidas e tecnologias já disponíveis atualmente, conforme apontado por Löfgren e Rootzén (2021). Ou seja, a produção de energética baseada na diversificação das respectivas fontes pode ser o caminho mais viável para redução das emissões dos GEE, visto que pequenas alterações nas respectivas participações relativas produzem efeitos positivos mais que proporcionais e, não necessariamente, demandam a introdução de novas tecnologias.

Dessa maneira, as reduções observadas nas simulações propostas, mediante o incremento na utilização das chamadas fontes limpas e renováveis de energia (neste caso, produtos da cana e eletricidade) viabilizam a implementação de estratégias e soluções técnicas imediatamente disponíveis para o desenvolvimento de sistemas energéticos de baixo carbono e até emissões líquidas zero, conforme observado por Treut et al. (2021).

Se nos últimos anos os países da América Latina vêm buscando alternativas para a substituição de combustíveis fósseis por biocombustíveis, mediante o uso da biomassa disponível (VEGA et al., 2024), países como o Brasil encontram-se em condição mais que privilegiada. Pois, além do uso da eletricidade produzida a partir de recursos hidrológicos abundantes, o segmento de IPPU brasileiro conta com possibilidade de utilizar a biomassa proveniente dos produtos da cana, o que geraria uma redução mais que proporcional aos 0,50% de incremento aqui simulados, conforme demonstrado pelos resultados das simulações resumidos na Tabela 4.

Por outro lado, 3 fontes sinalizaram elevação nas emissões de CO₂-GWP-AR5 ao serem substituídas por aquelas fontes de energia consideradas limpas, ou seja: lenha ($\Delta = 0,61\%$); gás natural ($\Delta = 0,72\%$); óleo combustível ($\Delta = 0,59\%$). Tal constatação pode ser considerada, em algum nível, uma contradição em relação ao comportamento empírico esperado, pois, ao reduzir a participação de fontes notadamente poluentes e elevar a participação de fontes consideradas limpas e renováveis de energia, esperar-se-ia que ocorresse uma redução nas emissões de CO₂-GWP-AR5. Contudo, nas simulações realizadas (em [C2], [C3] e [C8]), aconteceu o contrário.

Essa constatação pode ser considerada uma oportunidade, uma vez que, conforme observado por Araújo et al. (2024) ao descrever as questões dominantes que afetam o ritmo da transição energética, as inovações tecnológicas demandam a prontidão do ecossistema industrial para a promoção de adaptações na sua infraestrutura. Ou seja, segundo as simulações propostas, os setores do segmento de IPPU que demandam combustível baseado em lenha, gás natural e óleo combustível, precisarão realizar revisões tecnológicas acerca dos respectivos processos produtivos para se adequarem à nova realidade mundial. Sendo que, ao fazê-lo, isso pode ser considerada uma oportunidade para implementar mudanças voltadas para ganhos de eficiência energética que, segundo Andrei et al. (2021), é considerado o “primeiro combustível de um país”, uma vez que é o único combustível que todo o mundo pode explorar em abundância no caminho para um processo de transição energética rentável.

De qualquer forma, os resultados observados indicam que o processo de modelagem, previsão e simulação computacional, baseado em RNA MLP, conforme proposto na presente investigação científica, traz como desfecho primário a possibilidade de se avaliar objetivamente o impacto das alterações na matriz energética sobre as emissões de CO₂ da indústria brasileira.

Como desfecho secundário, decorrente do processo de simulação em si, os resultados observados neste trabalho científico possibilitaram identificar aquelas fontes de energia cuja substituição por fontes alternativas consideradas limpas e renováveis, ainda que em pequenos percentuais (1,00%), permitiriam reduzir mais que proporcionalmente as emissões de CO₂ do segmento industrial brasileiro como um todo. Por exemplo, comparativamente às emissões totais de observadas em 2020, tais reduções poderiam atingir até 10,30% no caso dos IPPU que utilizam GLP, ou 9,88% para aqueles utilizam óleo diesel, ou ainda, 6,86% para as IPPU que utiliza carvão vapor como fonte energética.

Adicionalmente, ainda como desfecho secundário, os resultados observados neste estudo sinalizaram que as substituições de combustíveis na matriz energética devem ser realizadas de maneira direcionada, ou ainda, de forma pontual e específica por tipo de combustível, uma vez que as reduções simultâneas em

todos os combustíveis integrantes da matriz energética dos IPPU ([C12]) não foram tão expressivas quanto às reduções observadas em cenários como aqueles cujas reduções percentuais foram propostas para uma só fonte, por exemplo, GLP, óleo diesel ou carvão vapor.

Tabela 4 – Cenários simulados para as emissões de CO₂-GWP-AR5, mediante aplicação de RNA MLP.

Ano / Cenário	2020 ^a	[C1]	[C2]	[C3]	[C4]	[C5]	[C6]	[C7]	[C8]	[C9]	[C10]	[C11]	[C12]
Produtos da cana	21,997%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,55%
Eleticidade	20,759%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,50%	+0,55%
Outras fontes primárias	10,258%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Lenha	8,808%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Gás natural	8,764%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Coque de carvão mineral	8,346%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Outras fontes secund. de petr.	6,793%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Carvão vegetal	4,696%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Carvão vapor	3,914%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	0,00%	-0,10%
Óleo combustível	1,728%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	0,00%	-0,10%
Gás de cidade e de coqueira	1,291%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	0,00%	-0,10%
GLP	1,211%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	0,00%	-0,10%
Óleo diesel	1,199%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	-1,00%	-0,10%
Biodiesel	0,141%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Alcatrão	0,095%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
Querosene	0,001%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%	0,00%
CO ₂ -GWP-AR5 (t)	102.246.265	101.939.425	102.870.191	102.980.478	100.364.669	101.495.222	101.035.982	95.232.884	102.846.537	97.783.148	91.712.073	92.144.990	100.894.075
CO ₂ -GWP-AR5 (Δ com base em 2020)	Δ= 0,00%	Δ= -0,30%	Δ= 0,61%	Δ= 0,72%	Δ= -1,84%	Δ= -0,73%	Δ= -1,18%	Δ= -6,86%	Δ= 0,59%	Δ= -4,37%	Δ= -10,30%	Δ= -9,88%	Δ= -1,32%
Legenda: (a)participação relativa de cada fonte no total consumido pela indústria nacional, segundo a matriz energética nacional, a partir da seguinte fórmula: participação relativa no total em % = [(consumo da fonte em 10 ³ tep / total em 10 ³ tep)100]													

Como desfecho secundário, decorrente do processo de simulação em si, os resultados observados neste trabalho científico possibilitaram identificar aquelas fontes de energia cuja substituição por fontes alternativas consideradas limpas e renováveis, ainda que em pequenos percentuais (1,00%), permitiriam reduzir mais que proporcionalmente as emissões de CO₂ do segmento industrial brasileiro como um todo. Por exemplo, comparativamente às emissões totais de observadas em 2020, tais reduções poderiam atingir até 10,30% no caso dos IPPU que utilizam GLP, ou 9,88% para aqueles utilizam óleo diesel, ou ainda, 6,86% para as IPUU que utiliza carvão vapor como fonte energética.

Adicionalmente, ainda como desfecho secundário, os resultados observados neste estudo sinalizaram que as substituições de combustíveis na matriz energética devem ser realizadas de maneira direcionada, ou ainda, de forma pontual e específica por tipo de combustível, uma vez que as reduções simultâneas em todos os combustíveis integrantes da matriz energética dos IPPU ([C12]) não foram tão expressivas quanto às reduções observadas em cenários como aqueles cujas reduções percentuais foram propostas para uma só fonte, por exemplo, GLP, óleo diesel ou carvão vapor.

5 Considerações finais

Ao simular comportamentos dinâmicos dos componentes do processo de conversão e uso da energia em produção, a modelagem de estruturas e sistemas energéticos demanda abstração da realidade e suposições específicas, entre outros fatores, a fim de representar situações simplificadas dos sistemas energéticos e econômicos reais (Felder e Kumar, 2021).

Adicionalmente, existe o contraste observado entre a descrição detalhada de modelos e seus atores, estruturas, processos e suas interações, à luz de uma perspectiva multinível e específica e, por isso, de difícil generalização, proposta recorrente pela literatura relacionada a sistemas de energia e à mitigação dos efeitos climáticos; comparativamente à literatura econômica que, normalmente, está centrada nas mudanças proporcionadas pela inovação e pela tecnologia, distanciando-se do rigor de modelos detalhados, sendo voltada para resultados mais generalizáveis (Löfgren e Rootzén, 2021).

O processo de modelagem, previsão e simulação computacional proposto nesta investigação científica utiliza, em grande medida, fatores de natureza tecnológica; contudo, justamente em função da natureza dos fatores tecnológicos utilizados, tal processo não requer descrição detalhada do respectivo modelo, suas estruturas e atores, apesar não deixar de levar em conta o processo de conversão e uso da energia na produção. Nesse sentido, pode-se afirmar que tal combinação de característica facilita sua generalização tanto para outras atividades econômicas dentro de uma mesma economia, quanto para outras economias (internacionais, por exemplo) em geral.

Como principal limitação desta pesquisa, destaca-se a ausência de dados mais recentes referentes às emissões de CO₂ no contexto brasileiro, referentes aos anos de 2021 e 2022, por exemplo, para que fosse possível mensurar a eficiência da RNA MLP implementada e utilizada nas simulações realizadas neste processo investigativo. Por outro lado, a quantidade e a diversidade de métricas avaliativas utilizadas para aferir o desempenho da respectiva RNA pôde assegurar-lhe um percentual médio de acerto superior a 99%.

Para a continuidade desta investigação sugere-se a utilização da metodologia analítica ora proposta aplicada à economia brasileira como um todo, em uma relação do tipo “total geral de emissões versus matriz energética geral”, ou ainda, o que parece ser mais interessante, a aplicação dessa metodologia em outros segmentos específicos da economia.

Assim, espera-se que os resultados apresentados possam ser somados aos achados científicos de outras pesquisa correlatas e, assim, contribuir para o planejamento estratégico em setores chave da economia, como energia, indústria e agricultura, entre outros, visando a sustentabilidade ambiental, viabilizando o desenvolvimento de políticas públicas mais efetivas na mitigação das emissões de gases de efeito estufa, mediante o fornecimento de uma possível ferramenta robusta para previsões mais confiáveis de emissões futuras.

Referências bibliográficas

Ali, K, Jianguo, D, Kirikkaleli, D, Mentel, G and Altuntaş, M (2023) ‘Testing the role of digital financial inclusion in energy transition and diversification towards COP26 targets and sustainable development goals’, *Gondwana Research*, v. 121, p. 293–306. <https://doi.org/10.1016/j.gr.2023.05.006>

- Andrei, M, Thollander, P, Pierre, I, Gindroz, B and Rohdin, P (2021) ‘Decarbonization of industry: guidelines towards a harmonized energy efficiency policy program impact evaluation methodology’, *Energy Reports*, v. 7, p. 1385–1395. <https://doi.org/10.1016/j.egy.2021.02.067>
- Araújo, OQF, Morte, IBB, Borges, CLT, Morgado, CRV and Medeiros, JL (2024) ‘Beyond clean and affordable transition pathways: a review of issues and strategies to sustainable energy supply’, *International Journal of Electrical Power & Energy Systems*, v. 155, Part A, p. 109544. <https://doi.org/10.1016/j.ijepes.2023.109544>
- Brasil, Ministério da Ciência, Tecnologia e Inovação (2023) *Sistema de Registro Nacional de Emissões (SIRENE): emissões de GEE por setor*. Brasília: MCTI.
- Carmo, CRS and Lima, AD (2018) ‘Métodos quantitativos e pesquisa contábil: um estudo de caso relacionado a pequenas amostras de dados’, *Contabilometria – Brazilian Journal of Quantitative Methods Applied to Accounting*, v. 5, n. 1, p. 92–109.
- CEBDS – Conselho Empresarial Brasileiro para o Desenvolvimento Sustentável (2017) *Opportunities and challenges of the Brazilian NDC goals for the business sector*. Rio de Janeiro: CEBDS.
- Collins, SD, Peek, N, Riley, RD and Martin, GP (2021) ‘Sample sizes of prediction model studies in prostate cancer were rarely justified and often insufficient’, *Journal of Clinical Epidemiology*, v. 133, p. 53–60. <https://doi.org/10.1016/j.jclinepi.2020.11.013>
- Efron, B (1979) ‘Bootstrap methods: another look at the jackknife’, *The Annals of Statistics*, v. 7, n. 1, p. 1–26.
- EPE – Empresa de Pesquisa Energética (2023) *Balanço energético nacional: séries históricas e matrizes consolidadas (1970–2022)*. Brasília: EPE.
- Felder, FA and Kumar, P (2021) ‘A review of existing deep decarbonization models and their potential in policymaking’, *Renewable and Sustainable Energy Reviews*, v. 152, p. 111655. <https://doi.org/10.1016/j.rser.2021.111655>
- Galaz, V, Centeno, MA, Callahan, PW, Causevic, A, Patterson, T, Brass, I, Baum, S, Farber, D, Fischer, J, Garcia, D, McPhearson, T, Jimenez, D, King, B, Larcey, P and Levy, K (2021) ‘Artificial intelligence, systemic risks, and sustainability’, *Technology in Society*, v. 67, p. 101741. <https://doi.org/10.1016/j.techsoc.2021.101741>
- Gupta, A, Davis, M and Kumar, A (2021) ‘An integrated assessment framework for the decarbonization of the electricity generation sector’, *Applied Energy*, v. 288, p. 116634. <https://doi.org/10.1016/j.apenergy.2021.116634>
- Hamed, MM, Mohammed, A and Olabi, AG (2023) ‘Renewable energy adoption decisions in Jordan’s industrial sector’, *Renewable and Sustainable Energy Reviews*, v. 184, p. 113568. <https://doi.org/10.1016/j.rser.2023.113568>
- Henderson, J and Sen, A (2021) *The energy transition: key challenges for incumbent and new players in the global energy system*. Oxford: Oxford Institute for Energy Studies.
- IPCC – Intergovernmental Panel on Climate Change (2018) *Global warming of 1.5°C: summary for policymakers*. Geneva: IPCC.
- Lampis, A, Martín, MMI, Zabaloy, MF, Soares, RS, Guzowski, C, Mandai, SS, Lazaro, LLB, Hermsdorff, SMGL and Bermann, C (2022) ‘Energy transition or energy diversification? Critical thoughts from Argentina and Brazil’, *Energy Policy*, v. 171, p. 113246. <https://doi.org/10.1016/j.enpol.2022.113246>
- Liu, F and Dai, Y (2023) ‘Product quality prediction method in small sample data environment’, *Advanced Engineering Informatics*, v. 56, p. 101975. <https://doi.org/10.1016/j.aei.2023.101975>
- Löfgren, Å and Rootzén, J (2021) ‘Brick by brick: governing industry decarbonization in the face of uncertainty and risk’, *Environmental Innovation and Societal Transitions*, v. 40, p. 189–202. <https://doi.org/10.1016/j.eist.2021.07.002>
- McRoberts, RE, Næsset, E, Hou, Z, Ståhl, G, Saarela, S, Esteban, J, Travaglini, D, Mohammadi, J and Chirici, G (2023) ‘How many bootstrap replications are necessary for estimating remote sensing-assisted

- model-based standard errors?', *Remote Sensing of Environment*, v. 288, p. 113455. <https://doi.org/10.1016/j.rse.2023.113455>
- Miniard, D and Attari, SZ (2021) 'Turning a coal state to a green state', *Energy Research & Social Science*, v. 82, p. 102292. <https://doi.org/10.1016/j.erss.2021.102292>
- Murakoshi, K (2005) 'Avoiding overfitting in multilayer perceptrons', *Biosystems*, v. 80, n. 1, p. 37–40. <https://doi.org/10.1016/j.biosystems.2004.09.031>
- Nadaleti, WC, Souza, EG and Souza, SNM (2022) 'The potential of hydrogen production from high- and low-temperature electrolysis methods', *International Journal of Hydrogen Energy*, v. 47, n. 82, p. 34727–34739. <https://doi.org/10.1016/j.ijhydene.2022.08.065>
- Nibedita, B and Irfan, M (2024) 'Energy mix diversification in emerging economies', *Renewable and Sustainable Energy Reviews*, v. 189, Part B, p. 114043. <https://doi.org/10.1016/j.rser.2023.114043>
- Pelissari, MR, Cañas, SSM, Barbosa, MO and Tassinari, CCG (2023) 'Decarbonizing coal-fired power plants', *Results in Engineering*, v. 19, p. 101249. <https://doi.org/10.1016/j.rineng.2023.101249>
- Santos, DA, Dixit, MK, Kumar, PP and Banerjee, S (2021) 'Assessing the role of vanadium technologies', *iScience*, v. 24, n. 11, p. 103277. <https://doi.org/10.1016/j.isci.2021.103277>
- Santos, FS, Nascimento, KKF, Jale, JS, Xavier Júnior, SFA and Ferreira, TAE (2024) 'Brazilian wind energy generation potential', *Renewable and Sustainable Energy Reviews*, v. 189, Part B, p. 113990. <https://doi.org/10.1016/j.rser.2023.113990>
- SEEG – Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (2023) *Emissões de CO₂ por setor: processos industriais*. São Paulo: Observatório do Clima.
- Shahbaz, M, Siddiqui, A, Ahmad, S and Jiao, Z (2023) 'Financial development as a determinant of energy diversification', *Energy Economics*, v. 126, p. 106926. <https://doi.org/10.1016/j.eneco.2023.106926>
- Treut, GL, Lefèvre, J, Lallana, F and Bravo, G (2021) 'The multi-level economic impacts of deep decarbonization strategies', *Energy Policy*, v. 156, p. 112423. <https://doi.org/10.1016/j.enpol.2021.112423>
- Vega, P, Bautista, KT, Campos, H, Daza, S and Vargas, G (2024) 'Biofuel production in Latin America', *Energy Reports*, v. 11, p. 28–38. <https://doi.org/10.1016/j.egyr.2023.10.060>
- Wang, M, Hui, G, Pang, Y, Wang, S and Chen, S (2023) 'Optimization of machine learning approaches for shale gas production forecast', *Geoenergy Science and Engineering*, v. 226, p. 211719. <https://doi.org/10.1016/j.geoen.2023.211719>
- Zambrano-Monserrate, MA (2024) 'Clean energy production index and CO₂ emissions in OECD countries', *Science of the Total Environment*, v. 907, p. 167852. <https://doi.org/10.1016/j.scitotenv.2023.167852>