

Previsão da evolução das emissões de Gases do Efeito Estufa (GEE) na Agricultura no Ceará, Brasil

Projected Greenhouse Gas (GHG) Emissions from Agriculture in Ceara, Brazil

Elizama Cavalcante de Paiva

Universidade Federal do Ceará - UFC. Fortaleza, CE. Brasil

José de Jesus Sousa Lemos

Universidade Federal do Ceará - UFC. Fortaleza, CE. Brasil. Pesquisador e Bolsista de Produtividade do CNPq.

Milena Monteiro Feitosa

Universidade Federal do Ceará - UFC. Fortaleza, CE. Brasil

GT4. Meio ambiente, agroecologia, sustentabilidade e mudanças climáticas

Resumo: As emissões de gases de efeito estufa (GEE) no setor agropecuário configuram um desafio ambiental estratégico, demandando, além da sua evolução temporal, a identificação dos fatores que as impulsionam para o fortalecimento de práticas sustentáveis. O presente estudo tem por objetivo principal investigar os determinantes e prever a evolução das emissões médias de GEE na produção agrícola no estado do Ceará no período 1970/2024. A metodologia estruturou-se em duas etapas: inicialmente, utilizou-se o método preditivo ARIMA (2,1,2) para projetar cenários para a próxima década (até 2034); na sequência, aplicou-se uma abordagem híbrida de Análise Fatorial e Redes Neurais Artificiais (RNA) para capturar a complexidade das relações entre as variáveis independentes e as emissões de GEE da Atividade Agrícola no estado. Como resultados, o modelo ARIMA apontou que, no cenário pessimista, com projeção de que as emissões continuarão a crescer a uma taxa de 2,38% ao ano. A análise espacial por quartis revelou uma elevada concentração das emissões, onde apenas 25% dos municípios (Quartil 4) responderam por 62% do volume total médio do estado. O modelo de RNA, utilizando as sinergias das variáveis originais extraídas via AF para compor sua camada de entrada, revelou que o desempenho econômico e a densidade pecuária (Fator 1, com 53,4% de impacto) e a degradação ambiental aliada à vulnerabilidade climática (Fator 2, com 46,6%) são os determinantes do sistema. Conclui-se que o estado se encontra em um ponto crítico, sendo urgente a implementação de políticas públicas efetivas de mitigação, como o fomento de práticas sustentáveis e a inibição do desmatamento, para que o cenário otimista (redução de 6,25% ao ano) seja alcançado.

Palavras-chave: *Variações climáticas; Concentração de CO₂; Continuidade da vida na Terra; Dinâmica das emissões de GEE; Redes Neurais Artificiais.*

Forecast of Greenhouse Gas (GHG) Emissions Trends in Agriculture in Ceará Estate, Brazil

Abstract: Greenhouse gas (GHG) emissions in the agricultural sector represent a strategic environmental challenge, requiring not only an understanding of their trends over time but also the identification of the factors driving them in order to strengthen sustainable practices. The main objective of this study is to investigate the determinants and forecast the evolution of average GHG emissions in agricultural production in the state of Ceará for the period 1970–2024. The methodology was structured in two stages: initially, the ARIMA (2,1,2) predictive method was used to project scenarios for the next decade (through 2034); subsequently, a hybrid approach combining Factor Analysis and Artificial Neural Networks (ANN) was applied to capture the complexity of the relationships between the independent variables and GHG emissions from agricultural activity in the state. As a result, the ARIMA model indicated that, in the pessimistic scenario, emissions are projected to continue growing at a rate of 2.38% per year. Spatial analysis by quartiles revealed a high concentration of emissions, with just 25% of municipalities (Quartile 4) accounting for 62% of the state's total average volume. The RNA model, which uses the synergies of the original variables extracted via FA to compose its input layer, revealed that economic performance and livestock density (Factor 1, with a 53.4% impact) and environmental degradation combined with climate vulnerability (Factor 2, with a 46.6% impact) are the key determinants of the system. It is concluded that the state is at a critical juncture, and the implementation of effective public mitigation policies—such as promoting sustainable practices and curbing deforestation—is urgent in order to achieve the optimistic scenario (a 6.25% annual reduction).

Keywords: *Climate variations; CO₂ concentration; Continuity of life on Earth; GHG emissions dynamics; Artificial Neural Networks.*

1. Introdução

As variações climáticas tornaram-se um dos temas mais urgentes e debatidos no cenário global, impulsionado pelo aumento das emissões de Gases do Efeito Estufa (GEE) e suas consequências socioambientais (IPCC, 2023; HU et al, 2022). Desde a Revolução Industrial, o aumento da concentração de dióxido de carbono (CO₂) na atmosfera tem acelerado o aquecimento do planeta. De acordo com o sexto relatório de avaliação do Painel Intergovernamental sobre Mudanças Climáticas (IPCC), em 2021, a concentração de CO₂ atingiu 410 partes por milhão (ppm), o maior nível em dois milhões de anos.

Esse aumento exacerbado das GEE torna-se crítico quando as concentrações superam a capacidade natural de absorção do planeta. Isso acontece, majoritariamente, em decorrência de atividades humanas, tais como: 1 - Queima de combustíveis fósseis como carvão mineral, gás natural e petróleo; 2 - Remoção de florestas; 3 – Processos industriais específicos; 4 – Emissões do setor de transportes e mobilidade urbana; 5 - Atividades agrícolas praticadas de forma inadequada, especialmente a criação de gado em elevadas concentrações por área que libera grandes quantidades de metano (CH₄) por meio da fermentação entérica. (Oreggioni et al., 2021; IPCC, 2023; Bortoletto et al., 2023).

Nesse contexto, a Organização das Nações Unidas para Agricultura e Alimentação (FAO, 2016) estima que o setor agrícola responda por até 21% das emissões mundiais. Diante deste cenário, são urgentes ações de mitigação das emissões de GEE, bem como de adaptações com a finalidade de amenizar os danos já causados pelo aumento da temperatura, além de implementar um presente sustentável como condição indispensável para poder ser garantido um futuro para a continuidade da vida na Terra (IPCC, 2023).

Por sua localização estratégica e por suas características climáticas o Ceará configura-se como um laboratório natural para o estudo das emissões de GEE. Dos 184 municípios do estado, 175 integram o semiárido brasileiro (CONDEL/SUDENE, 2024). Essa localidade enfrenta desafios, como a escassez hídrica crônica e a dependência de atividades econômicas sensíveis ao clima, como a agricultura. Logo, compreender a dinâmica das emissões de GEE no Ceará e em regiões semiáridas é estratégico para orientar políticas de adaptação climática e gestão de recursos.

Ancorada nesses fundamentos, esta pesquisa busca: 1) Estimar um modelo preditivo para as emissões no Ceará (1970-2024); 2) Projetar cenários para o período 2025-2034; 3) Aferir e comparar as taxas de crescimento históricas e projetadas; e 4) Verificar a significância das variáveis que influenciaram tais emissões entre 1985 e 2024.

Para buscar entender essas questões a pesquisa tem os seguintes objetivos específicos:

a – estimar um modelo que seja capaz de prever as emissões de GEE no Ceará no entre os anos de 1970 a 2024; b – desenhar cenários que mostrem como provavelmente deverão se comportar essas emissões entre os anos de 2025 a 2034; c – aferir a taxa de crescimento das emissões de GEE entre 1970 e 2024 e como provavelmente essa taxa se comportará nos 10 anos para os quais se farão as previsões nesta pesquisa; d – hierarquizar os municípios do estado pela média de emissão de GEE de 1970 a 2024; e - testar variáveis que provavelmente contribuíram para a elevação ou para a redução dessas emissões no período entre os ano de 1985 a 2024.

Além desta seção introdutória, a pesquisa contém mais quatro seções. A segunda seção apresenta as fontes dos dados e os métodos econométricos aplicados. A terceira seção traz discussões a respeito dos resultados estimados e a quarta é dedicada às considerações finais.

2. Metodologia

Nesta seção, apresenta-se a base de dados com as respectivas fontes, bem como as metodologias adotadas para alcançar os objetivos propostos.

2.1 Fontes e preparação dos dados utilizados na pesquisa.

A unidade de observação do estudo é o estado do Ceará que contém 184 municípios, dos quais 175 são reconhecidos oficialmente como fazendo parte do regime climático do semiárido brasileiro (Condel/Sudene, 2024). A região é caracterizada pela predominância do regime climático semiárido, com baixos índices pluviométricos anuais e geralmente instáveis (Lemos, 2015). O clima é marcado por alta evapotranspiração potencial, temperaturas elevadas e escassez hídrica crônica, com um período chuvoso concentrado majoritariamente entre os meses de fevereiro e maio (Funceme, 2025).

As informações originais utilizadas na pesquisa foram coletadas nos 184 municípios do estado do Ceará e depois agregadas pelas suas médias aritméticas para representar o cenário estadual. As variáveis com as respectivas fontes, períodos em que foram coletadas, bem como as respectivas unidades de medidas estão detalhadas no Quadro 01.

Quadro 1 – Variáveis e fontes de dados relativas às emissões de GEE no Ceará (1985-2024)

Variáveis	Unidade de medida	Período	Fonte
Média das emissões de gases do efeito estufa (GEE/ano)	toneladas de CO ₂ e gases equivalentes (e)	1985-2024 ¹	SEEG
Tempo (i = 0,1, ..., n)	ano	1985-2024	Criado na pesquisa
Áreas com lavouras permanentes e temporárias (ha)	hectares	1985-2024	MapBiomass
Áreas com Cicatrizes de fogo (ha)	hectares	1985-2024	MapBiomass
Áreas desmatadas (ha)	hectares	1985-2024	MapBiomass

Áreas em recuperação (ha)	hectares	1985-2024	MapBiomias
Áreas com pastagens (ha)	hectares	1985-2024	MapBiomias
Precipitação média de chuvas (mm) entre os meses de Janeiro e Junho de cada ano	milímetros	1985-2024	NOAA
Temperatura média (°C) entre os meses de Janeiro e Junho de cada ano	graus Celsius	1985-2024	NOAA
Valor da produção total (cultura permanente e temporária)	R\$ de 2024	1985-2024	PAM/IBGE
Efetivo de bovinos (quantidades)	unidades (cabeças)	1985-2024	PPM/IBGE

Fonte: Elaborada pelos autores.

Nota: 1 – os dados de emissões de GEE foram coletados em duas séries. Entre 1970 e 2024 para criar o modelo utilizado para fazer as previsões. Entre 1985 e 2024, para aferir as variáveis que se supõe interferem nas emissões de GEE.

As variáveis que, por hipótese, exercem influência nas emissões de GEE (Gases de Efeito Estufa) da atividade agrícola estão detalhadas no Quadro 2, onde se mostram os sinais esperados dos seus impactos: (+) aumentando as emissões de GEE; (-) reduzindo as emissões de GEE (Feitosa e Lemos, 2025; Feitosa, 2026).

Quadro 2 – Variáveis e relação esperada nas emissões de Gases do Efeito Estufa (GEE)

Variável	Definição	Relação Esperada	Fonte
Y_t	Emissão média anual de GEE	Não se aplica	SEEG
X_{i1}	Áreas com Cicatrizes de fogo (ha)	(+)	MapBiomias
X_{i2}	Áreas desmatadas (ha)	(+)	MapBiomias
X_{i3}	Bois / Pastagens	(+)	PPM/IBGE e MapBiomias
X_{i4}	Áreas em recuperação (ha)	(-)	MapBiomias
X_{i5}	Proxy da Aridez (Chuva/temperatura)	(-)	NOAA
X_{i6}	Valor da prod total por hec	(-)	PAM/IBGE e MapBiomias

Fonte: Elaborada pelos autores.

Acredita-se que as variáveis áreas com cicatrizes de fogo, áreas desmatadas e efetivo bovino por áreas de pastagens intensificam a emissão de Gases do Efeito Estufa (IPCC, 2023; Feitosa e Lemos, 2025; Feitosa, 2026). De modo oposto, as áreas recuperadas atuam como sequestradores de carbono da atmosfera por meio da fotossíntese o que, por sua vez, contribui com a diminuição da emissão de GEE (IPCC, 2023).

O valor da produção agrícola por hectare é utilizado como proxy da produtividade e/ou da renda média auferida em cada hectare colhido, uma vez que quando a propriedade produz mais por hectare ela tende a concentrar a atividade e reduzir a necessidade de expansão da fronteira agrícola para novas áreas (evitando o desmatamento).

A proxy do índice de aridez consiste na relação entre a precipitação de chuva e a temperatura, nesse sentido quanto maior for o valor referente a essa variável menor deve ser a emissão de GEE, tendo em vistas que a variável afere a quantidade de água advinda das chuvas que foi retida no solo. Marengo (2008) ressalta que ambientes com maior disponibilidade

hídrica (*Proxy* mais alta) apresentam maior resiliência da vegetação, menor taxa de mortalidade de plantas e menor biomassa seca disponível como combustível para queimadas. Em anos menos áridos, a decomposição é otimizada e o risco de incêndios de grande escala diminui drasticamente, reduzindo a emissão direta de GEE.

2.1 Metodologia para alcançar o primeiro objetivo: aferição da evolução das emissões de GEE

Para alcançar o primeiro objetivo da pesquisa utiliza a série histórica de emissões de GEE da atividade agrícola no Ceará (1970 a 2024). A série foi visualizada graficamente e submetida a testes estatísticos, como o teste de Dickey-Fuller Aumentado (ADF), para avaliar se era estacionária, condição essencial para a aplicação do modelo ARIMA que foi utilizado para fazer a previsão (Gujarati e Porter, 2011; Wooldridge, 2013).

Como o objetivo de buscar aferir as evoluções das emissões anuais de GEE da atividade agrícola, que nesta pesquisa é tratada como Y_t parte das seguintes premissas. Seja Y_t uma variável aleatória observada no t -ésimo período ($t = 1, 2, \dots, n$). Seja Y^P o valor projetado de Y_t , e que ϵ_t seja o termo aleatório que, por hipótese, atende aos fundamentos do modelo linear clássico, de ser “ruído branco”. Neste caso, os valores de (Y^P) que preveem os valores de (Y_t) podem ser sintetizados na equação (01).

$$Y^P = Y_t + \epsilon_t \quad (01)$$

O modelo é amplamente utilizado para a previsão de séries temporais univariadas e é representado como ARIMA (p,d,q), onde: p é a ordem da parte autorregressiva (AR); d é o número de diferenças necessárias para tornar a série estacionária (integração), caso não apresente originalmente essa característica e q é a da média móvel (MA).

Para estimar o modelo de previsão foram seguidas, resumidamente, as seguintes etapas: 1-Aferir se a série é estacionária. 2 - Identificação do modelo: Com base nos gráficos da função de autocorrelação (ACF) e autocorrelação parcial (PACF), identificaram-se os valores iniciais de p e q . 3 - Diagnóstico do modelo: Os resíduos dos modelos foram analisados para verificar a ausência de autocorrelação (teste de Ljung-Box), normalidade e homocedasticidade.

Com o modelo validado, gera-se o modelo adequado e estabelecem-se as previsões de emissões de GEE (Atividade agrícola) para os próximos 10 anos a partir do ano de 2024. A acurácia das previsões será avaliada por meio do coeficiente de determinação (R^2), a porcentagem do erro absoluto médio (MAPE), o Erro Quadrático Médio (MSE) e a Raiz do Erro Quadrático Médio (RMSE), Critério de Informação Bayesiano (BIC) normalizado que

afere a parcimônia do modelo. Estimam-se ainda o coeficiente de correlação linear de Pearson entre a série observada e a série prevista.

2.2 Metodologia para o segundo objetivo: Traçar os cenários

A partir das estimações geradas, foram traçados dois cenários considerados otimistas para estimações “menores” que as estimadas pela previsão central e “pessimistas” para estimações maiores que os previstos pelo ARIMA. As previsões centrais representarão as estimativas pontuais de emissão dos GEE em cada ano. Os limites inferiores e superiores serão estimados por meio do intervalo de confiança (intervalo de previsão) foram calculados com um nível de significância de 5% de probabilidade de erro.

Essa abordagem permite que o cenário otimista seja interpretado como o resultado de políticas de mitigação bem-sucedidas ou condições climáticas favoráveis à absorção de carbono, enquanto o cenário pessimista reflete a continuidade ou intensificação das pressões emissoras observadas na série histórica.

2.3 Metodologia para o terceiro objetivo: Taxa Geométrica de Crescimento (TGC)

Para aferir essa trajetória estima-se a Taxa Geométrica de Crescimento (TGC) tanto para o período histórico quanto para as projeções dos cenários otimista e pessimista (2025–2034).

Para estimar a TGC de uma variável aleatória Y_t considera-se:

$$Y_t = \lambda_0 \cdot e^{(\lambda_1 T + \epsilon_t)} \quad (02)$$

Na equação (02) a constante “e” se constitui na base dos logaritmos naturais; T é o tempo ($T = 0, 1, 2, \dots, n$); ϵ_t é o termo de erro aleatório que, por hipótese, atende aos pressupostos do modelo linear clássico. (Wooldridge, 2011)

Para viabilizar a estimação por Mínimos Quadrados Ordinários (MQO), aplica-se o logaritmo natural na equação (02) de forma a obter a seguinte equação:

$$\ln(Y_t) = \ln \lambda_0 + \lambda_1 T + \epsilon_t \quad (03)$$

Tomando a derivada do logaritmo natural de Y_t em relação ao tempo T chega-se ao seguinte resultado:

$$d[\ln(Y_t)]/dT = \lambda_1 \quad (04)$$

O coeficiente λ_1 apresentado inicialmente na equação (03) e na equação (04) é a taxa geométrica de crescimento instantâneo de Y_t (Wooldridge, 2011). Este procedimento permite comparar se o ritmo de crescimento projetado para a próxima década.

2.4 Metodologia para o quarto objetivo: Hierarquizar os municípios por emissão de GEE

Para a análise da distribuição espacial das emissões de GEE entre os municípios, utilizou-se a técnica de separação por quartis. Segundo Fávero e Belfiore (2017), o primeiro

quartil delimita os 25% dos valores inferiores da distribuição, enquanto o quarto quartil identifica os 25% dos valores superiores, ou seja, as unidades com maior magnitude do fenômeno estudado. Neste estudo, a aplicação dos quartis permitiu a estratificação dos 184 municípios do Ceará em quatro grupos distintos de emissão. O foco analítico recaiu sobre o Quartil Superior, que agrupa os municípios com os maiores volumes de emissão de GEE.

2.5 Metodologia para o quinto objetivo: Importância das variáveis das emissões de GEE

A investigação das variáveis que determinam as emissões de GEE na Atividade Agrícola no Ceará será realizada por meio de uma abordagem estatística em duas etapas: primeiro, a redução da dimensionalidade via Análise Fatorial (AF) e, posteriormente, a mensuração da importância relativa via Redes Neurais Artificiais (RNA).

Fávero e Belfiore (2017) sugerem algumas etapas fundamentais a AF que consiste em:

a) análise da matriz de correlações e adequações da utilização da AF; b) extração dos fatores iniciais e delimitação do número de fatores; c) rotação dos fatores; e d) interpretação dos fatores.

Para verificar a adequação da técnica de AF, utilizou os testes de Kaiser-Meyer-Olkin (KMO), o teste de esfericidade de Bartlett, a análise da matriz de correlação e a verificação da diagonal principal da matriz anti-imagem. Para a interpretação do KMO, considera-se 0,90-1,00: muito bom; 0,80-0,89: boa; 0,70-0,79: média; 0,60-0,69: razoável; 0,50-0,59: fraca e < 0,50: inaceitável. Já o teste *Test of Sphericity* (BTS) de Bartlett, verifica a hipótese de que a matriz de correlação é uma matriz identidade, ou seja, que não há correlação entre as variáveis. Foi mensurada ainda, a magnitude da variância explicada pelos componentes selecionados na análise fatorial (Hair *et al.*, 2005; Fávero *et al.*, 2009; Lemos, 2015).

Hair Junior *et al.* (2005) recomendam também a verificação do coeficiente de Pearson para examinar a relação entre cada par de variáveis. A existência de correlações estatisticamente significativas ($p < 0,05$) é o que indica que as variáveis compartilham variância comum, justificando a agregação fatorial.

Na sequência, fez-se a rotação dos fatores, que no caso proposto foi o Varimax, que facilita a interpretação ao redistribuir a variância de forma que cada variável apresente carga fatorial elevada em apenas um fator. Geralmente o primeiro fator tende a ser um fator geral com quase toda variável com carga significativa, e explica a quantia maior de variância. Cada fator explica porções sucessivamente menores de variância, demonstrando assim sua importância. De acordo com Hair *et al.* (2005), após estimar os fatores, obtém-se “eigenvalues” (autovalores) que podem ser usados como ponderadores da importância de cada um dos fatores.

A interpretação e entendimento das dimensões latentes obtidas na aplicação da análise fatorial descrevem os dados em número muito menor de conceitos do que as variáveis individuais originais. Para facilitar a interpretação, esses escores serão convertidos para valores positivos (em uma escala de 0 a 1), preservando a ordenação relativa entre as observações, já que valores negativos em um índice poderiam dificultar na interpretação dos resultados que se obtém.

Com esse procedimento, as variáveis explicativas das emissões de GEE serão os escores fatoriais que são obtidos pela sinergia das variáveis exibidas nos componentes principais gerados na pesquisa. Desta forma a relação entre as emissões de GEE e os escores fatoriais (EF_{j1} ; EF_{j2} , ..., EF_{jp}) pode ser descrita pela seguinte equação:

$$GEE_i = f(EF_{j1}; EF_{j2}, \dots, EF_{jp}) \quad (05)$$

Esta etapa é a base para a fase subsequente, na qual os escores fatoriais normalizados servirão como *inputs* (entradas) para o modelo de Redes Neurais Artificiais, permitindo aferir o peso e a importância de cada dimensão (fator) na composição das emissões de GEE no Ceará entre 1985 e 2024.


2.5.1 Redes Neurais Artificiais

Para concluir o quinto objetivo desta pesquisa, utilizou-se o modelo de Redes Neurais Artificiais (RNA) para investigar como as emissões de GEE da atividade agrícola são influenciadas pela sinergia dos Fatores gerados na AF (EF_{j1} ; EF_{j2} , ..., EF_{jp}).

Conforme Zhang (2003), as Redes Neurais Artificiais (RNAs) têm sido amplamente estudadas e usadas na previsão de séries temporais. A principal vantagem das RNAs é a capacidade que têm de fazer modelagem não linear flexível, além de apresentarem facilidade para analisar sistemas dinâmicos como séries temporais não estacionárias.

Em uma Rede Neural, os neurônios são funções às quais os dados são estimados e transformados em resposta, comportamento semelhante aos gerados no modelo de análise de regressão. Essa resposta é repassada para um ou mais neurônios da rede, de tal modo que, no final do processo, produz um resultado (Morettin; Singer, 2023). Desta forma, segundo Zhang *et al.* (1998), as RNAs “imitam” o cérebro humano, buscando reconhecer regularidades e padrões de dados, sendo capazes de aprender com a experiência e fazer generalizações baseadas em conhecimentos previamente acumulados.

Figura 01 – Representação de um neurônio artificial de McCulloch e Pitts



Fonte: Adaptado de Haykin (2001)

O modelo de neurônio artificial proposto por McCulloch e Pitts (1943) foi apresentado na Figura 01 de maneira bem simples, na qual os neurônios são conectados por canais de comunicação que estão associados a determinados pesos.

Os sinais de entrada ($X_1, \dots, X_n$) são transmitidos via conexões ponderadas pelos pesos sinápticos ($W_{k1}, \dots, W_{kn}$), convergindo para uma junção somadora, inicialmente de maneira linear.

$$Y = \sum W_{kn} X_n = W^T X \quad (06)$$

Nesta equação, para simplificar e integrar o termo do viés (b) à observação vetorial, define-se uma entrada fixa $X_0 = 1$ e um peso $W_0 = b$. Assim, o vetor de entrada será um vetor $X = 1, X_1, \dots, X_n$ e o vetor de pesos como $W = b, W_{k1}, \dots, W_{kn}^T$. A operação linear realizada pelo neurônio é dada pelo produto interno desses vetores (V_k):

$$V_k = \sum W_{kn} X_n \quad (07)$$

Os pesos sinápticos W_{kn} são selecionados por meio de um algoritmo de aprendizagem, a partir da série ou da matriz de dados que estão sendo estudados. Este algoritmo baseia-se na retropropagação do erro (*Backpropagation*), para ajustar os pesos das camadas intermediárias, de tal forma, que minimizem os erros aferidos a partir da diferença entre as séries observadas e as previstas (Zhang *et al*, 1998). Esses pesos sinápticos podem assumir inicialmente valores aleatórios, que serão atualizados usando os dados observados, na fase de treinamento, que acontece na camada oculta. Nas camadas ocultas, o potencial de ativação linear é modificado pela aplicação da função não linear pré-estabelecida na arquitetura.

Na sequência, esse resultado linear (V_k) é submetido à função de ativação (F), resultando no sinal de saída Y_k conforme expresso na Equação (08):

$$Y_k = F(\sum W_{kj} X_j + b_k) \quad (08)$$

Onde:

X_j = é o j -ésimo padrão de entrada (escore fatorial);

W_{kj} = é o j-ésimo peso sináptico do neurônio k;

b_k = termo de viés (bias) do neurônio k;

F = função de ativação do neurônio;

Y_k = sinal emitido pelo neurônio k (emissão de GEE estimada).

Assim, busca-se identificar e testar sinergias entre as variáveis originais reduzidas inicialmente aos componentes principais e posteriormente nos escores fatoriais que, por hipótese desta pesquisa, potencialmente impactaram as previsões de GEE no Ceará no período de 1985 a 2024. Ressalta-se ainda que a primeira camada (*inputs*) das RNAs foi alimentada pelos escores fatoriais gerados a partir da Análise Artificial conforme objetivo 03. Dessa forma, será possível investigar os efeitos das variáveis que possam ter influenciado de forma positiva ou negativa as projeções das emissões de GEE.

Por meio dessa metodologia, será possível, a partir de um modelo híbrido que permite integrar a Análise Fatorial com as Redes Neurais Artificiais e identificar de forma clínica as variáveis que influenciam no GEE.

3 Resultados e discussão

Nesta seção, apresentam-se e discutem-se os resultados alcançados, estruturados conforme a ordem dos objetivos específicos da pesquisa.

3.1 Resultados encontrados no primeiro objetivo – Modelo de predição GEE Ceará

A definição do modelo seguiu o protocolo de Box-Jenkins (2015) em que a análise visual da FAC original revelou um decaimento linear e persistente, característico de séries não estacionárias com tendência estocástica, confirmada pelo teste de Raiz Unitária Dickey-Fuller Aumentado (ADF). Os resultados oriundos do ADF inferiram que a série não era estacionária, uma vez que o teste resultou em um p-valor de 0,168. Com base neste resultado, não foi possível rejeitar a hipótese nula de não estacionariedade, concluindo assim que a série GEE é não estacionária e, portanto, requer diferenciação para sua estabilização (média, variância e covariância constantes) e por conseguinte aplicação da modelagem ARIMA.

Após o ajuste da série, a análise conjunta das funções (FACP e FAC) permitiu a identificação das ordens autorregressivas (p) e de média móvel (q).

Com base nessas análises, a série temporal de emissões de GEE da Atividade Agrícola no Ceará foi processada utilizando um modelo ARIMA (2,1,2). O modelo ajustado demonstrou um elevado desempenho preditivo. Com efeito, o coeficiente de determinação (R^2) foi de 0,926, demonstrando que a estrutura de defasagens e médias móveis consegue explicar 92,6% da variabilidade total dos dados históricos; o Erro Médio Absoluto Percentual (MAPE) foi de

19,83%; o Critério de Informação Bayesiano (BIC) Normalizado de 17,73; e o Coeficiente de Correlação de Pearson que consiste na relação entre os valores observados e estimados da série de emissões de GEE da Atividade Agrícola no estado foi de 0,963.

A qualidade do ajuste é reforçada pelo teste de Ljung-Box Q (18), que apresentou uma estatística de 13,259 com um p-valor de 0,506° que levou a aceitar a hipótese nula de que os resíduos gerados pelo modelo estimado se comportam como “ruídos brancos”.

Os resultados da estimativa do modelo ARIMA (2,1,2) sem a constante para as emissões de GEE da Atividade Agrícola no Ceará indicam uma forte dependência temporal da série. O componente autoregressivo de segunda ordem (AR 2) apresentou alta significância estatística, com um coeficiente de -0,729.

Os termos de média móvel de primeira e segunda ordem (MA 1) também se mostraram significantes em um nível menor do que 3%. Embora o primeiro termo autoregressivo (p-valor 0,123) e o segundo termo tenham excedido levemente o valor convencional de significância (p-valor de até 10%), a estrutura global do modelo (2,1,2), considerando que os demais parâmetros estimados apresentaram níveis de erros inferiores a 3% foi mantida visando a estabilidade dos resíduos e a capacidade preditiva.

Tabela 1 - Estimativa dos parâmetros do Modelo ARIMA (2,1,2) para fazer a previsão das emissões de GEE pelo setor agrícola do Ceará entre os anos de 1970 e 2024

Termo	Coeficiente	Erro Padrão	Estatística t	p-valor
AR (Retardo 1)	0,330	0,198	-1,951	0,123
AR (Retardo 2)	-0,729	0,173	-4,215	0,000
MA (Retardo 1)	0,586	0,264	-2,081	0,027
MA (Retardo 2)	-0,560	0,267	-1,384	0,023

Fonte: Elaborada pelos autores a partir dos dados da amostra.

3.2 Previsões de Emissões pelo Modelo ARIMA (2,1,2) e TGC

As previsões geradas pelo modelo ARIMA (2,1,2) possibilitaram a criação de cenários para as emissões de GEE da Atividade Agrícola no Ceará. Com base em uma margem de confiança de 95% foi possível criar cenários sob a ótica otimista e pessimista para o período 2025-2034, a partir da previsão central, cujas TGC estão sintetizadas na tabela 02.

Tabela 2 – Estimativa das TGC para emissão de GEE no Ceará no período 1970/2024 e com as projeções de 10 anos a partir de 2024

Cenário / Período	Constante (β_0)	TGC (Anual)	R ² Ajustado
Realizado (1970-2024)	7,409	7,58%	0,702
Cenário Otimista (2025-2034)*	10,639	-6,25%	0,955
Cenário Pessimista (2025-2034)*	11,253	2,38%	0,951

Fonte: Elaborada pelos autores a partir dos dados da amostra.

Nota: *Probabilidade do erro de previsão = 5%


Das evidências mostradas na Tabela 02 depreende-se que as emissões de GEE por parte da Atividade Agrícola dos 184 municípios do Ceará no lapso de tempo compreendido entre os anos de 1970 e 2024 foi de 7,58% ao ano. Vale lembrar que nesse intervalo aconteceram períodos de secas intensas como as de 1970 (583,70 mm), 1983 (375,49 mm), 1993 (452,83mm) e a mais longa que ocorreu entre 2012 e 2017 (NOAA, 2024). Nesses períodos, a mortalidade da vegetação e o manejo inadequado de pastagens sob estresse hídrico tendem a favorecer ocorrências de queimadas, inclusive as espontâneas e, por consequência elevar as emissões de GEE, justificando a magnitude da TGC observada ao longo da série.

O modelo projetou para um cenário otimista, que consiste na redução de emissões de GEE da Atividade Agrícola em 10 anos, uma taxa negativa de 6,25% ao ano, redução de 62.134 toneladas de CO₂e (2024) para 25.945 toneladas (2034). Essa projeção de TGC menor para os próximos 10 anos, pode ser atribuída a combinação de fatores a citar: as quadras chuvosas mais favoráveis observadas no Ceará entre 2018 e 2024, bem como pelos grandes projetos de projetos de infraestrutura hídrica para garantir o abastecimento de água tratada, especialmente regiões rurais do estado com vistas a enfrentar a seca recente passada no Estado (Cogerh, 2018).

A estrutura do modelo estimado, que tem uma componente autorregressiva com defasagem de 2 anos (ARIMA 2,1,2) indica que o comportamento das emissões é influenciado pelos níveis registrados nos dois anos anteriores. No contexto cearense, essa defasagem sugere que a dinâmica de GEE pode estar associada aos ciclos biológicos e climáticos em que anos com quadras chuvosas favoráveis promovem a recuperação da cobertura vegetal e a umidade do solo, o que por sua vez cria ambientes favoráveis que resultam em taxas de emissões mais controladas nos períodos subsequentes. Esses achados corroboram a hipótese de que a manutenção de solos cobertos e uma vegetação saudável atua como regulador natural, atenuando o ritmo de crescimento das emissões.

Em contrapartida, se nada for feito a estimativa aponta que as emissões continuarão a crescer (IPCC, 2023) a uma taxa de 2,38% ao ano.

Gráfico 1 – Previsão de Emissão de Gases do Efeito Estufa (GEE) (ton)



Fonte: Elaborada pelos autores.

Nota: Intervalo de confiança de 95%.

A volatilidade observada na série histórica de emissão de GEE da Atividade Agrícola no Ceará evidenciada pelos picos de 1995 (65.168,6 ton), 2023 (62.134,4 ton) e 2024 (63.776,9 ton), não é aleatória, mas ela espelha as transformações estruturais no Ceará. Ao dividir a série dos 54 anos em quartis, chama atenção o dado de que no quartil com maiores emissões de GEE da Atividade Agrícola do estado por ano, a grande maioria dos anos (7 dos 13) ocorreram nas últimas duas décadas. Esse cenário reforça que nas últimas décadas, apesar dos avanços tecnológicos, a pressão sobre os recursos naturais e o perfil das emissões não recuaram; pelo contrário, consolidaram-se em patamares elevados.

Essa tendência regional alinha-se às advertências do IPCC (2023), em que alerta que, caso as emissões globais de CO₂ persistam nos níveis atuais, o aquecimento global fatalmente ultrapassará o incremento de 2°C, com alta probabilidade de exceder o limite crítico de 1,5°C já nos próximos 20 anos. No contexto local, Feitosa (2025) enfatiza que o aumento das emissões está intrinsecamente ligado à intensificação produtiva, destacando-se a degradação por excesso de efetivo bovino em áreas de pastagem e o uso recorrente de queimadas.

3.3 Hierarquização dos municípios cearenses por emissão de GEE atividade agrícola (1970-2024)

A estratificação dos 184 municípios cearenses em quartis permitiu identificar a acentuada disparidade na distribuição espacial das emissões de GEE (Gráfico 02). O Quartil 4 (Q4), que compreende os 46 municípios com maiores volumes de emissão, apresenta valores que variam de 31.817,55 t (Paraipaba) a impressionantes 168.960,12 t (Tauá).

Observa-se que a maioria desses municípios possui grandes extensões territoriais e está localizada, predominantemente, nas regiões do Sertão Central e dos Inhamuns. Áreas que enfrentam as maiores dificuldades pluviométricas do estado (Funceme, 2025). Essa escassez hídrica limita as opções de diversificação agrícola, consolidando a pecuária extensiva como principal atividade econômica local.


No período analisado, o Q4 foi responsável por cerca de 62% das emissões médias da atividade agrícola do Ceará. Esse dado evidencia uma forte concentração da carga poluidora em áreas de alta vulnerabilidade climática, onde cidades como Tauá, Independência, Itapipoca e Bela Cruz se destacam com médias históricas superiores a 100 mil toneladas de GEE.

No extremo oposto, o Quartil 1 (Q1) revela o perfil de emissão mais baixo do estado, com destaque para o município de Guaramiranga (345,65 t). De acordo com os dados do SEEG (2024), a baixa representatividade desses municípios no inventário estadual deve-se à reduzida

extensão territorial e à predominância de economias voltadas ao setor de serviços e turismo sustentável. O Quartil 1 respondeu por cerca de, apenas, 4% das emissões médias da atividade agrícola do Ceará.

Geograficamente, muitos desses entes estão situados em microclimas úmidos ou serranos, onde a manutenção da cobertura vegetal nativa atua como um importante absorvidor de carbono (OLIVEIRA et al., 2021). Além disso, a ausência de grandes rebanhos bovinos elimina o impacto da fermentação entérica (Embrapa, 2023). Portanto, o Q1 representa um modelo de baixo impacto ambiental, onde a pressão sobre os recursos naturais é mitigada tanto pela escala geográfica quanto pela matriz econômica de baixo carbono.

Gráfico 1 – Distribuição espacial dos quartis por municípios emissores de GEE da Atividade Agrícola no Ceará – média dos anos de 1970 a 2024



Fonte: Elaborada pelos autores.

Uma vez estabelecida a visão espacial da distribuição das emissões de GEE na atividade agrícola no Ceará, torna-se imperativo investigar a influência da sinergia entre as variáveis que sustentam esses padrões.

3.4 Influência da sinergia entre as variáveis originais sobre as emissões de GEE no Ceará - Modelo Híbrido

Com a finalidade de aferir e investigar como as emissões de GEE são influenciadas pela sinergia dos fatores gerados no agrupamento das variáveis propostas, como já foi discutido neste trabalho, utilizou-se a técnica de Análise Fatorial (AF), empregando o método de extração por Componentes Principais.

Para validar a aplicação da técnica à base de dados, procedeu-se aos testes de adequação amostral. O teste de Kaiser-Meyer-Olkin (KMO) apresentou um poder moderado de explicação dos dados (0,601), porém perfeitamente aceitável para a natureza dos dados explorados. O teste de esfericidade de Bartlett, que apresentou resultado satisfatório, com Qui-Quadrado aproximado de 33,643 e significância estatística de 0,004. Os resultados permitiram rejeitar a hipótese nula de que a matriz de correlação é matriz identidade (Tabela 03).

Tabela 3 - Medida de adequação amostral (teste KMO) e teste de *Bartlett* (BTS)

Kaiser-Meyer-Olkin Measure of Sampling Adequacy.		0,601
Bartlett's Test of Sphericity	Approx. Chi-Square	33,643
	Df	15,00
	Sig.	0,004

Fonte: Elaborada pelos autores (2026).

Após a rotação ortogonal dos fatores e considerando a literatura, considerou-se apenas os fatores cujos valores de *eigenvalue* ou raiz característica são maiores que um, o modelo sintetizou as 6 variáveis em apenas 2 componentes principais ou fatores. Essa estrutura conseguiu explicar 55,78% da variância total dos dados original com uma perda mínima de informações (Tabela 04).

O Fator 1 representou 33,78% da variância total explicada pelas variáveis, este agrupamento, confirma uma das hipóteses que nortearam esta pesquisa de que a densidade de bovinos por hectare é um dos principais vetores provocadores de emissões de GEE pelas atividades agrícolas. Esse resultado corrobora com o relatório *The State of Food and Agriculture 2016* (SOFA) da FAO, que aponta o setor pecuário como um contribuinte significativo para as emissões agrícolas, representando cerca de 78% das emissões de metano (CH₄) do setor.

O segundo fator, por sua vez, explica 21,99% da variância total e a sua sinergia se concentra nas variáveis cicatriz de fogo (0,769) e desmatamento (0,754). A associação direta entre queimadas e desmatamento reflete o processo de mudança no uso da terra, atividade que, segundo dados da FAO (2016), é responsável por uma parcela considerável (cerca de 21% a 21,5%) das emissões globais de gases de efeito estufa (GEE) antropogênicos (Tabela 04).

Tabela 4 - Raiz característica, variância explicada pelo fator e variância acumulada

Fatores	Raiz Característica (<i>eigenvalues</i>)	Variância explicada pelo fator (%)	Variância acumulada (%)
Fator 01	2,027	33,786	33,786
Fator 02	1,32	21,998	55,785

Fonte: Elaborada pelos autores (2026).

A análise das cargas fatoriais após a rotação ortogonal (Tabela 5) permitiu identificar a estrutura latente das variáveis e definir a identidade de cada componente. Observe que o fator 01 tem maior influência do valor da produção por hectare (0,809) e, inversamente, por efetivo bovino/áreas por pastagens (-0,852). No fator 01 a proxy do índice de aridez (0,553) indica que o valor da produção e efetivo bovino/áreas com pastagens estão ligados a variabilidade climática. Destaca-se que o sinal negativo do efetivo bovino/áreas por pastagens sugere que a maior pressão do gado sobre a terra ocorre justamente quando os indicadores de clima e valor de produção estão baixos o que potencializa a degradação da cobertura vegetal e, consequentemente, eleva as emissões de GEE por unidade produzida.

O fator 2, por sua vez, tem a variável cicatriz de fogo apresentando a maior carga fatorial (0,726) e desmatamento (0,754). A proxy da aridez aparece nesse componente também com boa relevância, tendo em vista que a sua carga fatorial estimada foi de 0,483, indicando que reduções na proxy de Aridez (mais quente/seco) estão associados a um aumento na pressão ambiental, manifestada pelo uso do fogo e pela supressão de vegetação nativa.

Tabela 5 - Componentes (cargas fatoriais) e comunicações

Variáveis		Componentes		Comunicações
		F1	F2	
Cicatriz de Fogo	X ₁	0,031	0,769	0,592
Proxy Aridez	X ₂	0,553	-0,483	0,540
Valor_Hec	X ₃	0,809	0,190	0,691
Boi_Pastagem	X ₄	-0,852	-0,201	0,767
Desmatamento	X ₅	0,273	0,754	0,643
Recuperação	X ₆	-0,339	-0,006	0,115

Fonte: Elaborada pelos autores.

Embora a variável Recuperação tenha apresentado uma comunicação de 0,115, sua manutenção no modelo é estatisticamente justificada pela Medida de Adequação Individual (MSA) de 0,740, valor considerado bom pela literatura (Hair *et al*, 2009). Paradoxalmente, essa foi a variável com maior MSA na matriz de correlação anti-imagem. Essa informação indica que a variável de recuperação ambiental descreve um fenômeno (recuperação ambiental) que ainda é muito pequeno ou desconexo dos outros (fogo, boi, desmate) no Ceará.

Assim conclui-se a primeira etapa do modelo híbrido, ressaltando que ela não se limita à simples redução de dados, mas sim à identificação das sinergias latentes entre as variáveis originais que resultaram na criação dos dois escores fatoriais (EF1 e EF2), via Análise Fatorial, que permitiu capturar a variância compartilhada e os comportamentos conjuntos que variáveis isoladas não conseguiriam expressar.

Logo, os escores fatoriais assumem o papel de inputs (entradas) fundamentais para o modelo de RNA. Não obstante, essa transição que caracteriza a natureza do modelo híbrido: ao invés vez de alimentar a rede com dados brutos, utilizou-se a sinergia dos componentes fatoriais, garantindo que a RNA processe as interações complexas já pré-estruturadas.

Sob a ótica da modelagem, a preservação da variável (recuperação de áreas) permite que o algoritmo capture interações não lineares essenciais para a resiliência climática, as quais seriam omitidas em métodos puramente lineares caso a variável fosse excluída. Dessa forma, o modelo de RNA foi aplicado para testar essas relações complexas e identificar o peso relativo de cada vetor sobre a variação das emissões de GEE. Os resultados referentes à arquitetura da rede e à importância das variáveis estão apresentados na Tabela 06.

Tabela 6 - Resultados da estimativa utilizando RNA, com o índice de emissões de GEE como variável dependente e os escores fatoriais gerados a partir dos componentes EF1 e EF2 em que os dados originais foram reduzidos

Erro relativo no período de treinamento (%)	0,395
Erro relativo no período de teste (%)	0,126
Número de unidades na camada oculta, incluindo 1 camada oculta de polarização	3
Importância da Variável Independente	
Variáveis	Importância (pesos)
F1	0,534
F2	0,466
Teste de Acurácia	
RMSE	13,19
MAE	9,26
MAPE	36,54

Fonte: Elaborada pelos autores.

Observa-se que o erro relativo no período de teste (0,126) foi substancialmente menor que o do período de treinamento (0,395). Este resultado atesta a robustez estatística do modelo, confirmando a capacidade de generalização do modelo para prever a trajetória das emissões de GEE da Atividade Agrícola do Ceará face a dados não observados.

Em relação à importância das variáveis independentes, a RNA revelou como os escores fatoriais estruturais, identificados previamente na Análise Fatorial, impactam o volume de emissões. O escore fatorial 1 (EF1), que sintetiza as pressões produtivas e econômicas (fortemente marcado pela ocupação pecuária e pelo valor da terra), assumiu o papel de maior relevância na determinação das emissões, com um peso explicativo (53,4%). Logo em seguida, o Escore Fatorial 2 (EF2), que traduz a pressão ambiental direta (desmatamento, cicatrizes de fogo e severidade climática pela *proxy* de aridez), demonstrou uma importância de 46,6%.

Estes pesos confirmam que as emissões de GEE da Atividade Agrícola na região não são impulsionadas por um único vetor isolado, mas sim por uma sinergia quase equiparada e complexa entre a dinâmica agropecuária (EF1) e a degradação ambiental aliada à vulnerabilidade climática (EF2). Além disso, a precisão do ajuste é ratificada pelos baixos valores dos testes de acurácia (RMSE, MAE e MAPE) indicando que o modelo híbrido (AF + RNA) foi uma ferramenta aceitável para a prática do estudo ora apresentado.

4 Considerações finais

O presente estudo alcançou seu objetivo de investigar os determinantes e prever a evolução das emissões de Gases do Efeito Estufa (GEE) na produção agrícola do estado do Ceará, utilizando uma modelagem metodológica robusta que integrou o método preditivo ARIMA (2,1,2) a um modelo híbrido de Análise Fatorial e Redes Neurais Artificiais (RNA).

As projeções realizadas para a próxima década (2024 a 2034) revelaram que o estado se encontra em um ponto de inflexão crítico para a governança climática regional. O modelo ARIMA previu um cenário pessimista de crescimento contínuo das emissões a uma taxa de 2,38% ao ano caso intervenções estruturais não sejam adotadas. Por outro lado, demonstrou-se a viabilidade de um cenário otimista, com uma redução média de 6,25% ao ano, o que faria as emissões recuarem para 23.824,6 toneladas de emissão de GEE até 2034, nível significativamente inferior à média histórica do período.

A análise espacial por quartis evidenciou uma acentuada disparidade geográfica nessas emissões. Identificou-se que apenas 25% dos municípios (Quartil 4) são responsáveis por 62% da carga poluidora agrícola do estado, concentrados majoritariamente nas regiões do Sertão Central e Inhamuns. Esse padrão espacial revela que a vasta extensão territorial e a vulnerabilidade pluviométrica dessas áreas forçam uma especialização na pecuária extensiva, consolidando-as como focos críticos para políticas de mitigação.

A aplicação do modelo híbrido (Análise Fatorial e RNA) permitiu compreender as raízes desse problema, confirmando que as emissões de GEE na região fazem parte de uma sinergia complexa entre vetores econômicos e ambientais. O Escore Fatorial 1, associado às pressões produtivas (fortemente influenciado pela dinâmica da pecuária e pelo valor da terra), apresentou a maior relevância na determinação das emissões, com peso explicativo de 53,4%. Com importância quase equiparada (46,6%), o Escore Fatorial 2 traduziu os impactos da pressão ambiental direta e da vulnerabilidade climática da região, agrupando variáveis como desmatamento, queimadas (cicatrizes de fogo) e a aridez do clima. Destacou-se ainda a importância da proxy da aridez, uma vez que a variável atuou nos dois escores fatoriais positivo

no escore fatorial 1 e negativo no escore fatorial 2, inferindo reduções na proxy de Aridez (mais quente/seco) estão associados a um aumento na pressão ambiental, manifestada pelo uso do fogo e pela supressão de vegetação nativa.

A pesquisa também destacou o papel das áreas em recuperação de áreas degradadas, que, apesar de atuarem de forma independente das pressões produtivas ou de degradação, são mecanismos essenciais de sequestro de carbono e interação de forma não linear com a resiliência climática do semiárido.

Portanto, conclui-se que é imprescindível a implementação de políticas públicas efetivas e estratégias de financiamento orientadas à redução das emissões e à preservação da capacidade hídrica do estado. O alcance do cenário otimista exigirá um esforço coordenado para reduzir o desmatamento e as queimadas, promover práticas pecuárias sustentáveis de baixo carbono e incentivar fortemente a recuperação de áreas degradadas no semiárido.

REFERÊNCIAS

BORTOLETTO, W. W.; PACAGNELLA JUNIOR, A. C.; CABELLO, O. G. Exploring the scientific literature on clean development mechanisms: A bibliometric analysis. **Energy Policy**, v. 183, p. 113806, 2023. Disponível em: <https://doi.org/10.1016/j.enpol.2023.113806>.

BOX, G.E. Et Al. Time Series Analysis Forecasting And Control. New Jersey, Wiley. Fifth Edition. 2015.

COGERH. Secretaria dos Recursos Hídricos. Companhia de Gestão dos Recursos Hídricos. **Plano de ações estratégicas de recursos hídricos do Ceará**. Fortaleza, 2018.

EMBRAPA. **Gases de Efeito Estufa na Pecuária Brasileira: Protocolos de Medição e Inventários**. Brasília: Embrapa Informação Tecnológica, 2023

FÁVERO, L. P.; BELFIORE, P. Manual de análise de dados. Rio de Janeiro: Elsevier, 2017.

FEITOSA, Milena Monteiro; LEMOS, José de Jesus Sousa. **Hybrid Model of Artificial Neural Networks and Principal Component Decomposition for Predicting Greenhouse Gas Emissions in the Brazilian Region of MATOPIBA**. Global Journal of Human-Social Science: E Economics, [s. l.], v. 25, n. 1, 2025.

FEITOSA, Milena Monteiro. **Impactos econômicos, sociais e ambientais na produção de soja no MATOPIBA**. 2025. 141 f. Tese (Tese em Desenvolvimento e Meio Ambiente) – Centro de Ciências, Universidade Federal do Ceará, Fortaleza, 2025.

GUJARATI, Damodar N.; PORTER, Dawn C. **Econometria básica**. 5. ed. Porto Alegre: AMGH, 2011. 924 p. ISBN 9788563308320.

HAIR Jr., J. F.; ANDERSON, R. E.; TATHAM, R. L.; BLACK, W. C. **Análise multivariada de dados**. 5. ed. Porto Alegre: Bookman, 2005.

HAIR JR., J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. Análise multivariada de dados. 6. ed. Porto Alegre: Bookman, 2009. 288 p.

HAIR, J. F., BABIN, B. J., ANDERSON, R. E., BLACK, W. C. (2018). Multivariate Data Analysis (8th ed.). Cengage.

HU, S. et al. Spatial pattern of the effects of human activities on the land surface of China and their spatial relationship with the natural environment. *Environment, Development and Sustainability*, v. 24, p. 10379-10401, 2022.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). **Tabela 1612**: Área plantada, área colhida, produção e valor da produção das lavouras temporárias. Rio de Janeiro: IBGE, 2024. Disponível em: <https://sidra.ibge.gov.br>. Acesso em: 17 jan. 2026.

LEMOS, J.J.S. Variações climáticas, seca e resiliência no semiárido brasileiro. **Painel 5 do 60º Congresso da Sociedade Brasileira de Economia e Sociologia Rural**. Natal, RN. 2022.

LEMOS, J.J.S.; BEZERRA, F.N.R. Interference of pluviometric instability in the forecast of grain production in the semiárido of Ceará, Brazil. **Braz. J. of Develop.**, Curitiba, v. 5, n. 9, p. 15632-15652. sep. 2019.

OLIVEIRA, J. G. et al. **Dinâmica florestal e estoque de carbono em matas de galeria no Nordeste brasileiro**. *Revista Brasileira de Geografia Física*, v. 14, n. 2, 2021.

ORGANIZAÇÃO DAS NAÇÕES UNIDAS PARA A ALIMENTAÇÃO E A AGRICULTURA (FAO). **The state of food and agriculture 2016 (SOFA)**: climate change, agriculture and food security. Roma: FAO, 2016. Disponível em: [link do site]. Acesso em: 3 mar. 2026.

OREGGIONI, G. D. et al. Climate change in a changing world: Socio-economic and technological transitions, regulatory frameworks and trends on global greenhouse gas emissions from EDGAR v.5.0. **Global Environmental Change**, v. 70, p. 102350, 2021. Disponível em: <https://doi.org/10.1016/j.gloenvcha.2021.102350>.

PAINEL INTERGOVERNAMENTAL SOBRE MUDANÇAS CLIMÁTICAS (IPCC). *Mudanças Climáticas 2023: Relatório Síntese*. Contribuição dos Grupos de Trabalho I, II e III para o Sexto Relatório de Avaliação. Genebra: IPCC, 2023. Disponível em: <https://miro.com/pt/relatorios/o-que-sao-relatorios/>. Acesso em: 18 fev. 2026.

SEEG Brasil – O Sistema de Estimativas de Emissões e Remoções de Gases de Efeito Estufa (SEEG) oferece dados em tempo real, que apoiam a transformação necessária para enfrentar os desafios globais que afetam todas as regiões brasileiras.[s. l.], 2025. Disponível em: <https://seeg.eco.br/>. Acesso em: 5 fev. 2026.