

NÍCHOLAS DE PAULA NICOMEDES

**ANÁLISE DA AUTOCORRELAÇÃO ESPAÇO-TEMPORAL NO BRASIL
DAS EMISSÕES DE GASES ASSOCIADOS ÀS MUDANÇAS
CLIMÁTICAS COM INDICADORES SOCIOECONÔMICOS**

Sorocaba
2026

PROGRAMA DE PÓS-GRADUAÇÃO em

*ciências
ambientais*

NÍCHOLAS DE PAULA NICOMEDES

**ANÁLISE DA AUTOCORRELAÇÃO ESPAÇO-TEMPORAL NO BRASIL
DAS EMISSÕES DE GASES ASSOCIADOS ÀS MUDANÇAS
CLIMÁTICAS COM INDICADORES SOCIOECONÔMICOS**

Dissertação apresentada como requisito para a
obtenção do título de Mestre em Ciências
Ambientais da Universidade Estadual Paulista
"Júlio de Mesquita Filho" na Área de
Concentração Diagnóstico, Tratamento e
Recuperação Ambiental

Orientador: Prof. Dr. Darllan Collins da Cunha e
Silva

Sorocaba
2026

N656a

Nicomedes, Nícholas de Paula

Análise da autocorrelação espaço-temporal no Brasil das emissões de gases associados às mudanças climáticas com indicadores socioeconômicos / Nícholas de Paula Nicomedes. -- Sorocaba, 2026
78 p. : il., tabs.

Dissertação (mestrado) - Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia, Sorocaba
Orientador: Darllan Collins da Cunha e Silva

1. Fatores socioeconômicos. 2. Gases estufa. 3. Análise multivariada. 4. Análise espacial (Estatística). I. Título.

IMPACTO POTENCIAL DESTA PESQUISA

A pesquisa contribui para o avanço científico ao integrar análises espaço-temporais das emissões de GEE e indicadores socioeconômicos. Oferece subsídios para políticas públicas sustentáveis associadas às mudanças climáticas, com impacto regional e nacional, reforçando a inovação, o conhecimento científico e a inserção internacional.

POTENTIAL IMPACT OF THIS RESEARCH

The research contributes to scientific advancement by integrating spatio-temporal GHG emissions and socioeconomic indicators analysis. It supports sustainable public policies related to climate change, with regional and national impact, reinforcing innovation, scientific knowledge, and international integration.

CERTIFICADO DE APROVAÇÃO

TÍTULO DA DISSERTAÇÃO: Análise da autocorrelação espaço-temporal no Brasil das emissões de gases associados às mudanças climáticas com indicadores socioeconômicos

AUTOR: NÍCHOLAS DE PAULA NICOMEDES

ORIENTADOR: DARLLAN COLLINS DA CUNHA E SILVA

Aprovado como parte das exigências para obtenção do Título de Mestre em Ciências Ambientais, área: Diagnóstico, Tratamento e Recuperação Ambiental pela Comissão Examinadora:

Prof. Dr. DARLLAN COLLINS DA CUNHA E SILVA (Participação Virtual)
Departamento de Engenharia Ambiental / UNESP / Câmpus de Sorocaba - ICTS

Prof. Dr. RAPHAEL DE VICQ FERREIRA DA COSTA (Participação Virtual)
Departamento de Ciências da Terra / Universidade do Minho

Prof. Dr. RENAN ANGRIZANI DE OLIVEIRA (Participação Virtual)
Departamento de Engenharias / Universidade de Sorocaba (UNISO)

Sorocaba, 06 de fevereiro de 2026.

Dedico este trabalho a Deus, origem e sentido deste caminho. Dedico-o aos meus pais e a quem, pela confiança silenciosa e pelo apoio constante, tornou possível a construção desta trajetória acadêmica.

AGRADECIMENTOS

Expresso minha gratidão a Deus, pela sustentação ao longo desta jornada e pela serenidade concedida nos momentos de maior exigência intelectual e pessoal.

Aos meus pais, pelo apoio constante, pela confiança nas minhas escolhas e por sempre valorizarem a educação como fundamento da minha trajetória.

À Flávia e ao Gustavo, cuja amizade foi essencial durante esse percurso. A presença e as conversas tiveram papel importante nos momentos mais desafiadores.

À Ana Beatriz, por caminhar ao meu lado em cada etapa, pela confiança constante, e pela presença que trouxe leveza e pelo apoio silencioso e firme que fez diferença diária nesta trajetória.

Ao Professor Dr. Darllan Collins, meu orientador, pela orientação criteriosa, pela exigência técnica e pelo compromisso com a formação científica. Sua condução foi fundamental para o amadurecimento deste trabalho e da minha trajetória acadêmica.

Ao Grupo de Estudos de Análise Espacial de Dados (GEAD) pela parceria diária, pelo ambiente acolhedor e pela atmosfera colaborativa que tornaram o processo de pesquisa mais leve e produtivo, marcado pelo trabalho conjunto e pela troca constante de experiências.

À Universidade Estadual Paulista (UNESP), Instituto de Ciência e Tecnologia de Sorocaba, e ao Programa de Pós-Graduação em Ciências Ambientais, pela estrutura acadêmica e pelas oportunidades de formação que possibilitaram o desenvolvimento desta pesquisa.

A todos que, de alguma forma, contribuíram para esta etapa, registro meu sincero reconhecimento.

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) - Código de Financiamento 001.

“Com a ciência a gente mergulha, mas a
natação pra subir e enxergar o todo de
novo é com a fé”

(BTCast ABC2, 2022).

RESUMO

As emissões de gases de efeito estufa (GEE) representam um dos principais fatores associados às mudanças climáticas contemporâneas, apresentando forte heterogeneidade espacial relacionada a processos socioeconômicos e demográficos. Este estudo avalia a variabilidade espaço-temporal das emissões municipais de GEE no Brasil entre 1999 e 2023, analisando suas relações com fatores socioeconômicos e demográficos, incluindo Produto Interno Bruto (PIB) per capita, índice de urbanização (IU) e densidade demográfica (DD). A abordagem metodológica integrou técnicas estatísticas abrangendo correlação de Spearman, análises de autocorrelação temporal e modelagens estatísticas com regressão linear múltipla (RLM; *Multiple Linear Regression*, MLR), modelo linear generalizado (MLG; *Generalized Linear Model*, GLM), regressão quantílica (RQ; *Quantile Regression*, QR) e modelo linear misto (MLM; *Linear Mixed Model*, LMM) com ajuste para heterocedasticidade temporal. Complementarmente, foram aplicadas análises de autocorrelação espacial por meio dos índices de Moran Global (GISA) e Local (LISA), permitindo a identificação de padrões de autocorrelação espacial. Os resultados evidenciaram associações positivas significativas entre IU (0,68), PIB per capita (0,52) e emissões de CO_{2eq}, indicando que municípios mais urbanizados e economicamente desenvolvidos possuem maiores níveis de emissão. Também foi verificado que municípios com alta DD apresentam maiores emissões (correlação de 0,6), embora não necessariamente com PIB per capita elevado (correlação de -0,02). A inclusão da dependência temporal e variabilidade entre municípios revelou que as emissões municipais se tornaram mais heterogêneas ao longo dos anos, indicando mudanças estruturais nas condições locais. As análises de GISA revelaram autocorrelação espacial estatisticamente significativa para todas as variáveis e anos ($p < 0,01$), bem como uma estabilidade para toda a série temporal avaliada, exceto pelo PIB per capita, que apresentou a maior amplitude de GISA (0,131998). Para os gases, o dióxido de carbono (CO₂) de origem fóssil apresentou o maior valor de GISA (0,583623) e o metano (CH₄) o menor valor (0,237889). Os dados socioeconômicos revelaram maior agregação espacial no IU (0,486798) e menor no PIB per capita (0,253622). Os resultados de LISA evidenciaram agrupamentos de altas emissões concentradas nas regiões Sul e Sudeste, principalmente nas capitais e regiões litorâneas, e agrupamentos de baixas emissões no Norte e Nordeste, padrão semelhante para IU e DD, entretanto, distinto para o PIB per capita, com padrões de alta renda per capita também na região Centro-Oeste. A baixa variação do número de municípios por agrupamento nos anos de maior e menor GISA, para todas as variáveis, evidencia a persistência de desigualdades estruturais. A incorporação simultânea da dimensão espacial e temporal revelou que as emissões não ocorrem de forma aleatória, mas são condicionadas por dinâmicas territoriais persistentes. Evidencia-se, portanto, a relevância de abordagens integradas e diferenciadas para políticas ambientais eficazes, considerando fatores socioeconômicos, demográficos e temporais no contexto brasileiro, que levem em conta os perfis espaciais dos municípios brasileiros, em consonância com as metas de desenvolvimento sustentável e os compromissos internacionais relacionados as mudanças climáticas.

Palavras-chave: PIB per capita; densidade demográfica; índice de urbanização; gases de efeito estufa; estatística espacial; correlação de dados.

ABSTRACT

Greenhouse gas (GHG) emissions represent one of the main factors associated with contemporary climate change, exhibiting strong spatial heterogeneity linked to socioeconomic and demographic processes. This study evaluates the spatiotemporal variability of municipal GHG emissions in Brazil between 1999 and 2023, analyzing their relationships with socioeconomic and demographic factors, including Gross Domestic Product (GDP) per capita, urbanization index (IU), and population density (PD). The methodological approach integrated statistical techniques encompassing Spearman correlation, temporal autocorrelation analyses, and statistical modeling using multiple linear regression (MLR), generalized linear model (GLM), quantile regression (QR), and linear mixed model (LMM) with adjustment for temporal heteroscedasticity. Additionally, spatial autocorrelation analyses were applied using the Global Moran's Index (GISA) and Local Moran's Index (LISA), allowing the identification of spatial autocorrelation patterns. The results showed significant positive associations between IU (0.68), GDP_{per capita} (0.52), and CO_{2eq} emissions, indicating that more urbanized and economically developed municipalities exhibit higher emissions. It was also found that municipalities with high PD present higher emissions (correlation of 0.6), although not necessarily with high GDP_{per capita} (correlation of -0.02). The inclusion of temporal dependence and variability among municipalities revealed that municipal emissions became more heterogeneous over the years, indicating structural changes in local conditions. GISA analyses revealed statistically significant spatial autocorrelation for all variables and years ($p < 0.01$), as well as stability throughout the evaluated time series, except for GDP_{per capita}, which showed the most significant GISA amplitude (0.131998). Among the gases, fossil-origin carbon dioxide (CO₂) presented the highest GISA value (0.583623), and methane (CH₄) the lowest (0.237889). Socioeconomic data revealed greater spatial aggregation in IU (0.486798) and lower GDP_{per capita} (0.253622). LISA results showed clusters of high emissions concentrated in the South and Southeast regions, especially in capital cities and coastal areas, and clusters of low emissions in the North and Northeast, a pattern also observed for IU and PD. However, high-income clusters were also found in the Central-West region for GDP_{per capita}. The low variation in the number of municipalities per cluster in the years of highest and lowest GISA, for all variables, highlights the persistence of structural inequalities. The simultaneous incorporation of spatial and temporal dimensions revealed that emissions do not occur randomly, but are conditioned by persistent territorial dynamics. Therefore, the relevance of integrated and differentiated approaches for effective environmental policies is highlighted, considering socioeconomic, demographic, and temporal factors in the Brazilian context, and accounting for the spatial profiles of municipalities, in line with sustainable development goals and international commitments related to climate change.

Keywords: GDP per capita; population density; urbanization index; greenhouse gases; spatial statistics; data correlation.

LISTA DE FIGURAS

Figura 1 - Dispersão dos valores das variáveis de emissão de GEE nos municípios ao longo do período analisado	40
Figura 2 - Dispersão dos valores das variáveis ambiental agregada, socioeconômicas e demográfica nos municípios ao longo do período analisado	41
Figura 3 - Variação temporal variáveis de emissão de GEE considerando estatísticas de tendência central e dispersão	42
Figura 4 - Variação temporal das variáveis ambiental agregada, socioeconômicas e demográfica considerando estatísticas de tendência central e dispersão	43
Figura 5 - Histogramas da distribuição dos valores das variáveis nos municípios brasileiros	44
Figura 6 - Gráficos $Q-Q$ das variáveis analisadas antes da transformação dos dados	45
Figura 7 - Histogramas da distribuição dos valores após a transformação matemática e remoção dos outliers das variáveis nos municípios brasileiros	46
Figura 8 - Gráficos $Q-Q$ das variáveis analisadas depois da transformação matemática e remoção dos outliers	47
Figura 9 - Matriz de correlação de Spearman	48
Figura 10 - Estrutura de dependência temporal identificada pela ACF	51
Figura 11 - Evolução do GISA para os GEE e CO _{2eq} nos municípios brasileiros entre 1999 e 2023	56
Figura 12 - Evolução do GISA para os indicadores socioeconômicos nos municípios brasileiros entre 1999 e 2023	57
Figura 13 - Distribuição espacial das emissões de CO ₂ de origem fóssil nos municípios brasileiros	58
Figura 14 - Distribuição espacial das emissões de CO ₂ de origem biogênica nos municípios brasileiros	59
Figura 15 - Distribuição espacial das emissões de CH ₄ nos municípios brasileiros	60
Figura 16 - Distribuição espacial das emissões de N ₂ O nos municípios brasileiros	61
Figura 17 - Distribuição espacial das emissões de CO ₂ equivalente (GWP-100) nos municípios brasileiros	62
Figura 18 - Distribuição espacial do PIB per capita nos municípios brasileiros	63
Figura 19 - Distribuição espacial da densidade demográfica nos municípios brasileiros	64
Figura 20 - Distribuição espacial do índice de urbanização nos municípios brasileiros	65

LISTA DE TABELAS

Tabela 1 - Estatísticas descritivas das variáveis de emissão de GEE	38
Tabela 2 - Estatísticas descritivas das variáveis ambiental agregada, socioeconômicas e demográfica	39
Tabela 3 - Comparações interanuais das variáveis com base no teste de correlação Dunn	49

LISTA DE ABREVIATURAS E SIGLAS

AA	Alto-Alto
AB	Alto-Baixo
ACF	Função de Autocorrelação
AIC	<i>Akaike Information Criterion</i>
AR6	Sexto Relatório de Avaliação
BA	Baixo-Alto
BB	Baixo-Baixo
BIC	<i>Bayesian Information Criterion</i>
CAPES	Coordenação de Aperfeiçoamento de Pessoal de Nível Superior
CH ₄	Metano
CO ₂ bio	Dióxido de carbono de origem biogênica
CO ₂ fóssil	Dióxido de carbono de origem fóssil
CO _{2eq}	Dióxido de carbono equivalente
CV	Coefficiente de variação
DD	Densidade demográfica
EDGAR	<i>Emission Database for Global Atmospheric Research</i>
ESRI	<i>Environmental Systems Research Institute</i>
GEE	Gás de efeito estufa
GISA	Índice de Moran Global
GLM	<i>Generalized Linear Model</i>
GWP	Potencial de Aquecimento Global
IBGE	Instituto Brasileiro de Geografia e Estatística
IDW	<i>Inverse Distance Weighted</i>
IEA	<i>International Energy Agency</i>
IPCC	Painel Intergovernamental sobre Mudanças Climáticas
IQR	Intervalo Interquartil
IU	Índice de urbanização

JRC	<i>Joint Research Centre</i>
LISA	Índice de Moran Local
LMM	<i>Linear Mixed Model</i>
MLG	Modelo linear generalizado
MLM	Modelo linear misto
MLR	<i>Multiple Linear Regression</i>
N ₂ O	Óxido nitroso
NS	Não Significativo
ODS	Objetivo de Desenvolvimento Sustentável
PIB _{per capita}	Produto Interno Bruto per capita
PIB	Produto Interno Bruto
QR	<i>Quantile Regression</i>
REML	Máxima Verossimilhança Restrita
RLM	Regressão linear múltipla
RMSE	Erro quadrático médio
RQ	Regressão quantílica
UCT	Uso e Cobertura da Terra
UNDESA	Departamento de Assuntos Económicos e Sociais das Nações Unidas
UNFCCC	Convenção-Quadro das Nações Unidas sobre Mudança do Clima
VIF	Fator de Inflação da Variância
WGS	<i>World Geodetic System</i>

LISTA DE SÍMBOLOS

x_p	Valor interpolado
x_i	Valor de emissão do ponto i
d_i	Distância euclidiana entre o ponto interpolado e o ponto de emissão i
n	Número de pontos considerados na vizinhança
a_i	Coefficiente de proporcionalidade do incremento da população
b_i	Coefficiente linear de correção
P_{est}	População estimada
P_i	População do município i
P	População da unidade de federação
t	Ano calculado
t_0	Censo 1
t_1	Censo 2
P_{mun}	População do município
A_{mun}	Área total do município
A_{urb}	Área urbanizada do município
Q_1	Primeiro quartil
Q_3	Terceiro quartil
β_0	Intercepto
$\beta_1, \beta_2, \beta_3$	Intercepto das variáveis explicativas
ε	Erro residual
n	Número correspondente de municípios
y_i	Valor do atributo considerado no município i
y_j	Valor do atributo considerado no município j
y	Valor médio do atributo na região de estudo
w_{ij}	Pesos atribuídos conforme a conexão entre as áreas i e j
I_i	Índice de Moran Local

SUMÁRIO

1	INTRODUÇÃO	15
2	OBJETIVOS	17
2.1	Objetivo geral.....	17
2.2	Objetivos específicos.....	17
3	REVISÃO DA LITERATURA.....	18
3.1	Impactos da intensificação das atividades antrópicas sobre o clima	18
3.2	GEE e seus impactos na mudança do clima	19
3.3	Impactos da mudança do clima sobre a sociedade	20
4	MATERIAL E MÉTODOS	22
4.1	Aquisição e elaboração da base de dados espaciais	22
<i>4.1.1</i>	<i>Emissões de GEE.....</i>	<i>22</i>
<i>4.1.2</i>	<i>Produto Interno Bruto per capita</i>	<i>24</i>
<i>4.1.3</i>	<i>Densidade Demográfica</i>	<i>24</i>
<i>4.1.4</i>	<i>Índice de Urbanização.....</i>	<i>25</i>
4.2	Estruturação e organização dos dados	26
4.3	Análises exploratórias e estatísticas	27
<i>4.3.1</i>	<i>Estatística descritiva.....</i>	<i>27</i>
<i>4.3.2</i>	<i>Visualização gráfica</i>	<i>27</i>
4.4	Tratamento estatístico das variáveis.....	28
<i>4.4.1</i>	<i>Tratamento de dados</i>	<i>28</i>
<i>4.4.2</i>	<i>Detecção de outliers</i>	<i>29</i>
<i>4.4.3</i>	<i>Teste de Normalidade.....</i>	<i>30</i>
4.5	Avaliação da dependência estatística entre as variáveis	30
<i>4.5.1</i>	<i>Correlação entre variáveis</i>	<i>30</i>
<i>4.5.2</i>	<i>Análise de multicolinearidade</i>	<i>31</i>
4.6	Comparação Temporal das Variáveis	31
<i>4.6.1</i>	<i>Avaliação da variabilidade temporal das variáveis.....</i>	<i>31</i>
<i>4.6.2</i>	<i>Análise de Autocorrelação Temporal.....</i>	<i>31</i>
4.7	Modelagem estatística	32
<i>4.7.1</i>	<i>Regressão linear múltipla (RLM; Multiple Linear Regression, MLR).....</i>	<i>32</i>
<i>4.7.2</i>	<i>Modelo linear generalizado (MLG; Generalized Linear Model, GLM)</i>	<i>33</i>
<i>4.7.3</i>	<i>Regressão quantílica (RQ; Quantile Regression, QR).....</i>	<i>33</i>

4.7.4	<i>Modelo misto linear (MLM; Linear Mixed Model, LMM)</i>	34
4.8	Análise espacial das variáveis	35
4.8.1	<i>Índice de Moran Global</i>	35
4.8.2	<i>Índice de Moran Local</i>	36
5	RESULTADOS	38
5.1	Caracterização descritiva e padrões de distribuição das variáveis	38
5.2	Adequação estatística dos dados e detecção de outliers	43
5.3	Análise de dependência linear e multicolinearidade entre preditores	47
5.4	Análise da dependência temporal e persistência estatística das variáveis ..	49
5.5	Modelagem estatística das emissões de CO_{2eq}	52
5.5.1	<i>RLM</i>	52
5.5.2	<i>MLG</i>	53
5.5.3	<i>RQ</i>	53
5.5.4	<i>MLM</i>	54
5.6	Autocorrelação espacial global	55
5.6.1	<i>Emissões de GEE</i>	55
5.6.2	<i>Indicadores socioeconômicos e demográficos</i>	56
5.7	Autocorrelação espacial local	57
5.7.1	<i>Emissões de GEE</i>	57
5.7.2	<i>Indicadores socioeconômicos e demográficos</i>	62
6	DISCUSSÃO	66
7	CONCLUSÃO	70
	REFERÊNCIAS	71

1 INTRODUÇÃO

As emissões globais de gases de efeito estufa (GEE) são amplamente reconhecidas como os principais impulsionadores das mudanças climáticas antropogênicas. O Sexto Relatório de Avaliação do Painel Intergovernamental sobre Mudanças Climáticas (IPCC, 2023) destaca que a queima de combustíveis fósseis e as alterações no uso da terra contribuíram significativamente para o aumento das concentrações de GEE na atmosfera. Essa trajetória compromete os esforços globais para limitar o aquecimento do planeta, ampliando a frequência e intensidade de eventos climáticos extremos, com efeitos adversos sobre ecossistemas e populações vulneráveis (IPCC, 2018; Rajão *et al.*, 2022; IPCC, 2023).

A mitigação das emissões é fundamental para o cumprimento do Acordo de Paris, que visa limitar o aquecimento global a valores inferiores a 2°C, com esforços para restringi-lo a 1,5 °C, em relação aos níveis pré-industriais (UNFCCC, 2015; Obergassel *et al.*, 2025; Riahi *et al.*, 2022). Além disso, a ação climática constitui um dos eixos centrais da Agenda 2030 das Nações Unidas, especialmente no que se refere ao Objetivo de Desenvolvimento Sustentável (ODS) 13, que propõe ações urgentes no enfrentamento da mudança do clima (UN, 2015; UNDESA, 2025).

Países em desenvolvimento exercem papel estratégico nesse cenário global, não apenas por seus processos acelerados de crescimento urbano e econômico, mas também pela diversidade de suas matrizes energéticas, padrões de uso da terra e estruturas de governança ambiental (Olsson *et al.*, 2019; IPCC, 2023). O Brasil, embora não figure entre os maiores emissores globais em termos absolutos, possui um perfil de emissões marcado por especificidades, como a predominância do desmatamento e das mudanças no uso da terra como vetores de emissão, especialmente em regiões associadas à conversão de florestas para a agropecuária (Mendes *et al.*, 2020; Dutra *et al.*, 2024).

Apesar da elevada participação de fontes renováveis na matriz elétrica brasileira, observa-se o crescimento da utilização de combustíveis fósseis no setor de transportes, elevando as emissões de dióxido de carbono de origem fóssil (CO₂ fóssil) (Wang *et al.*, 2021). Além do CO₂ fóssil, dióxido de carbono de origem biogênica (CO₂ bio) e outros gases como o metano (CH₄) e o óxido nitroso (N₂O) exercem forte influência no balanço radiativo da Terra, com potenciais de aquecimento global 28 e 298 vezes superiores ao do CO₂, respectivamente, em horizontes de 100 anos (Forster *et al.*, 2021; Li *et al.*, 2024).

A relação entre o desenvolvimento socioeconômico e as emissões de GEE tem sido amplamente estudada, indicando que fatores como Produto Interno Bruto (PIB) per capita,

densidade demográfica (DD) e índice de urbanização (IU) exercem papel determinante nos padrões de emissão (Bhusal; Sapkota, 2022; Raihan, 2024; Yang *et al.*, 2024). Regiões mais urbanizadas e com maior concentração de renda tendem a apresentar emissões per capita mais elevadas devido à maior demanda energética e ao consumo de bens e serviços (Guo *et al.*, 2022; Sufyanullah; Ahmad; Ali, 2022). Por outro lado, políticas ambientais, inovações tecnológicas e mudanças estruturais podem promover a dissociação entre crescimento econômico e emissões (Ko; Lee, 2022; González-Sánchez; Martín-Ortega, 2020).

Modelagens estatísticas, como regressões lineares, modelos mistos e econométricos, têm sido utilizadas para explorar essas relações. No entanto, a maioria dos estudos ainda se baseia em médias agregadas nacionais ou estaduais, negligenciando a variabilidade intra-regional e os padrões espaciais de concentração ou dispersão das emissões e de seus determinantes (Ren *et al.*, 2019; Wang *et al.*, 2021).

A heterogeneidade territorial brasileira, combinada com a elevada assimetria socioeconômica entre os municípios, exige abordagens que considerem explicitamente a dimensão espacial dos fenômenos (Capelari *et al.*, 2020). A análise espacial por meio dos Índices de Moran Global (GISA) e Local (LISA) oferece uma ferramenta robusta para identificar a existência de autocorrelação espacial entre municípios, revelando a presença de *clusters* estatisticamente significativos de altas ou baixas emissões, bem como de condições socioeconômicas semelhantes (Anselin; Syabri; Kho, 2009; Zhu *et al.*, 2022).

As variáveis socioeconômicas e demográficas apresentam distribuições espaciais complexas, refletindo padrões históricos de ocupação do território, processos de metropolização e expansão urbana desordenada. Compreender como essas variáveis se organizam territorialmente é fundamental para o planejamento urbano e ambiental (Fontoura; Pugliesi; Tachibana, 2023; Young, 2013).

Considerando a escassez de estudos que integrem a análise espaço-temporal das emissões de GEE com indicadores socioeconômicos e demográfico em escala municipal no Brasil, e reconhecendo que padrões espaciais estruturados podem revelar desigualdades ambientais persistentes, a hipótese deste estudo é que as emissões de GEE apresentam autocorrelação espacial significativa e estão associadas a níveis mais elevados de urbanização, densidade demográfica e desenvolvimento econômico nos municípios brasileiros ao longo do período analisado.

2 OBJETIVOS

2.1 Objetivo geral

Analisar as relações espaço-temporais das mudanças climáticas com fatores ambientais, socioeconômicos e demográficos, a fim de compreender as correlações e os padrões desses fatores nos municípios brasileiros para o período de 1999-2023.

2.2 Objetivos específicos

- Analisar estatisticamente os dados de emissão anual dos principais GEE (CO_2 fóssil, CO_2 bio, CH_4 e N_2O) e indicadores socioeconômicos e demográficos (PIB per capita, DD e IU);
- Relacionar os dados de emissão de GEE com os indicadores socioeconômicos e demográficos através de abordagens de correlação e de modelagens estatísticas;
- Analisar a autocorrelação espacial dos municípios brasileiros por meio dos índices de Moran (GISA e LISA) para fatores ambientais, socioeconômicos e demográficos;

3 REVISÃO DA LITERATURA

3.1 Impactos da intensificação das atividades antrópicas sobre o clima

A intensificação das atividades humanas ao longo das últimas décadas consolidou-se como a principal força motriz das alterações observadas no sistema climático. O IPCC AR6 (2021) demonstra que o aquecimento global recente é predominantemente causado pelo aumento das concentrações de CO₂, CH₄ e N₂O resultantes de ações antrópicas, com efeitos diretos sobre o balanço radiativo. Esses processos refletem transformações econômicas, territoriais e tecnológicas que se intensificaram ao longo do período analisado nesta dissertação (1999–2023).

O crescimento econômico, a urbanização e a ampliação da demanda energética constituem vetores centrais do aumento das emissões de GEE. Estudos indicam que padrões urbanos densos e expansões periféricas elevam o consumo energético e os fluxos de transporte, ampliando emissões de CO₂ (Jones; Kammen, 2014; Li *et al.*, 2022). Evidências também mostram que níveis mais elevados de renda, densidade demográfica e urbanização tendem a intensificar pressões ambientais, embora com variações regionais importantes (Liu *et al.*, 2022; Van der Borgh; Barbera, 2023). Isso sustenta a inclusão dos indicadores de PIB per capita, índice de urbanização e densidade demográfica nas análises deste estudo.

Bases globais como o EDGAR reforçam que emissões de GEE exibem forte heterogeneidade espacial, associada à organização produtiva e ao grau de urbanização (Crippa *et al.*, 2024). O Global Carbon Budget (Friedlingstein *et al.*, 2022) também mostra persistência do crescimento das emissões fósseis e manutenção de padrões espaciais marcados, indicando que a distribuição das atividades humanas configura arranjos territoriais não aleatórios. Essa evidência justifica o uso de métodos de autocorrelação espacial para investigar a lógica de distribuição das emissões municipais.

No Brasil, a intensificação das atividades antrópicas apresenta padrões específicos. Regiões Norte e Centro-Oeste concentram emissões relacionadas à mudança de uso da terra e à expansão agropecuária, enquanto Sul e Sudeste exibem emissões associadas a atividades urbanas e industriais (Sousa-Neto *et al.*, 2018; Chimel; Guilhoto; Gatti, 2011). Essas diferenças refletem desigualdades estruturais e persistência de padrões regionais de emissões, também observados em análises de cadeias produtivas e fluxos comerciais entre estados (Sanguinet, 2022).

A dimensão demográfica contribui adicionalmente para intensificar pressões ambientais, sobretudo em contextos urbanos com alta densidade populacional. Dinâmicas populacionais influenciam padrões de consumo, mobilidade e uso de recursos, reforçando a relação entre crescimento urbano e emissões (Muttarak, 2021). Essa perspectiva demográfica complementa o uso da densidade populacional como variável explicativa neste estudo.

3.2 GEE e seus impactos na mudança do clima

Os GEE diferem quanto à capacidade de absorção da radiação infravermelha, tempo de residência atmosférica e intensidade do forçamento radiativo, propriedades que explicam suas contribuições diferenciadas para a mudança do clima. Avaliações físicas e observacionais indicam que CO₂, CH₄ e N₂O são responsáveis pela maior parcela do forçamento radiativo antrópico líquido desde o período pré-industrial, ainda que atuem em escalas temporais e magnitudes distintas (Ehhalt *et al.*, 2001; IPCC, 2021; Canadell *et al.*, 2021; Bruhwiler *et al.*, 2021).

O CO₂ constitui o principal componente do aquecimento global devido ao elevado volume de emissões e ao seu caráter cumulativo, associado ao longo tempo de permanência na atmosfera. As principais fontes incluem a queima de combustíveis fósseis, processos industriais e mudanças no uso da terra, que alteram os estoques de carbono terrestre e atmosférico (Canadell *et al.*, 2021; Abreu *et al.*, 2024). Inventários globais e análises históricas demonstram crescimento persistente das emissões de CO₂ desde o século XIX, com forte concentração espacial em regiões urbanas e industrializadas (Friedlingstein *et al.*, 2022; Crippa *et al.*, 2024; Jones *et al.*, 2023).

O CH₄, embora apresente menor tempo de residência atmosférica, possui potencial de aquecimento global significativamente superior ao do CO₂ em horizontes temporais curtos, desempenhando papel relevante na intensificação recente do aquecimento (Etminan *et al.*, 2016; Mar *et al.*, 2022). Suas principais fontes antrópicas incluem a agropecuária, o manejo de resíduos e atividades ligadas à produção de petróleo e gás. Evidências observacionais indicam aceleração no crescimento das concentrações globais de CH₄ nas últimas décadas, reforçando sua importância climática e seus impactos adicionais sobre ecossistemas e saúde humana (Bruhwiler *et al.*, 2021; IPCC, 2021; Jones *et al.*, 2023).

O N₂O apresenta elevado potencial de aquecimento global e tempo de residência atmosférica superior a um século, apesar de ser emitido em menores quantidades absolutas. Suas emissões estão fortemente associadas ao uso de fertilizantes nitrogenados e a processos

microbianos em solos agrícolas, refletindo a intensificação dos sistemas produtivos agropecuários (Ehhalt *et al.*, 2001; IPCC, 2021; Abreu *et al.*, 2024). Estudos históricos e inventários recentes indicam crescimento contínuo das concentrações de N₂O, com padrões espaciais fortemente relacionados às áreas de agricultura intensiva (Jones *et al.*, 2023; Crippa *et al.*, 2024).

Para integrar os efeitos climáticos de gases com propriedades físicas distintas, utiliza-se o conceito de dióxido de carbono equivalente (CO_{2eq}), que permite avaliar o impacto agregado das emissões a partir de seus potenciais de aquecimento global. Indicadores observacionais, como o Annual Greenhouse Gas Index, demonstram aumento contínuo da influência combinada de CO₂, CH₄ e N₂O sobre o balanço energético do planeta, refletindo a intensificação do forçamento climático ao longo do tempo (Bruhwiler *et al.*, 2021; IPCC, 2023).

3.3 Impactos da mudança do clima sobre a sociedade

Os impactos da mudança do clima sobre a sociedade têm sido amplamente documentados na literatura científica, com ênfase em efeitos sobre saúde, segurança alimentar, atividades produtivas e desigualdades socioespaciais. Adom (2024) e Afzal, Din e Hasan (2024) destacam que países em desenvolvimento apresentam maior vulnerabilidade devido à dependência de setores sensíveis ao clima, menor capacidade adaptativa e desigualdades históricas.

A segurança alimentar constitui um dos eixos mais diretamente afetados com alterações em regimes de chuva, temperatura e padrões de sazonalidade que influenciam produtividade agrícola, disponibilidade de alimentos e estabilidade das cadeias de abastecimento. Estudos mostram que esses efeitos comprometem a segurança alimentar e nutricional, especialmente em populações vulneráveis (Alpino *et al.*, 2022), e tendem a se agravar em regiões onde mudanças climáticas afetam diretamente a agricultura de base familiar (Adom, 2024).

A saúde pública é outro componente crítico. A intensificação de ondas de calor, enchentes, secas e eventos extremos aumenta a incidência de doenças e agrava condições já prevalentes. Pesquisas apontam que populações periféricas estão mais expostas a riscos sanitários devido à combinação entre condições ambientais adversas e infraestrutura insuficiente (Alpino *et al.*, 2022; Barcellos *et al.*, 2025). Esses impactos incluem o aumento de doenças respiratórias, circulatórias e infecciosas, além de efeitos indiretos relacionados à insegurança hídrica e alimentar (SPC, 2023).

Ao ponto de vista socioeconômico, Afzal, Din e Hasan (2024) e Adom (2024) indicam que mudanças climáticas reduzem produtividade, afetam renda e ampliam vulnerabilidades sociais de famílias e setores produtivos. Esses efeitos são particularmente evidentes em regiões rurais dependentes da agricultura, onde variações climáticas afetam diretamente a segurança humana e a estabilidade dos meios de subsistência (Dutse, 2024). Em áreas urbanas, impactos climáticos sobre infraestrutura, mobilidade, abastecimento de água e energia afetam a organização territorial e aumentam custos sociais e econômicos (BRASIL, 2025).

A literatura científica também evidencia que impactos climáticos se manifestam em múltiplas escalas e setores, incluindo água, energia, saúde, agricultura e infraestrutura (Santos-Degner *et al.*, 2025). A ampliação da frequência e intensidade de eventos extremos – como secas severas, enchentes, tempestades e queimadas – produz perdas materiais, eleva riscos à saúde e pode gerar deslocamentos populacionais, afetando a coesão social e a capacidade das localidades de responder à crise (SPC, 2023; BRASIL, 2025). Esse conjunto de efeitos tende a repercutir de forma desigual, reforçando vulnerabilidades socioespaciais preexistentes e aprofundando desigualdades regionais (Adom, 2024; Alpino *et al.*, 2022).

4 MATERIAL E MÉTODOS

4.1 Aquisição e elaboração da base de dados espaciais

4.1.1 Emissões de GEE

A obtenção de dados sobre as emissões antrópicas de GEE foi realizada por meio da plataforma *Emission Database for Global Atmospheric Research* (EDGAR), versão v9.0 (2024). O banco de dados, desenvolvido pelo *Joint Research Centre* (JRC) em colaboração com a *International Energy Agency* (IEA), fornece inventários anuais de emissões globais de GEE harmonizados e espacialmente detalhados.

Para este estudo, foram adquiridos dados de emissões de CO₂, CH₄ e N₂O para todos os anos do período analisado (1999-2023). A plataforma EDGAR disponibiliza emissões globais brutas associadas a diferentes atividades antrópicas, incluindo combustão de combustíveis fósseis, processos industriais, atividades agrícolas e emissões biogênicas reportadas pela IEA, garantindo maior precisão nos cálculos de emissão total.

Após a aquisição, os dados foram processados para adequação à escala municipal. A plataforma disponibiliza as emissões na forma de pontos vetoriais distribuídos globalmente, sem um refinamento específico para os limites administrativos municipais. Dessa forma, foi necessária a interpolação espacial dos dados para obter uma distribuição contínua das emissões e viabilizar a análise municipal. Esse processo foi realizado no ArcMap 10.8 (ESRI, 2020), inicialmente com o recorte dos pontos de emissão para o território brasileiro, com base na malha territorial oficial obtida do Instituto Brasileiro de Geografia e Estatística (IBGE), e, posteriormente, com a aplicação do método *Inverse Distance Weighted* (IDW) para interpolação.

A interpolação IDW (Equação 1) foi escolhida devido à sua capacidade de gerar superfícies contínuas a partir de dados pontuais, assumindo que os pontos mais próximos possuem maior influência na estimativa do valor interpolado. Esse método é amplamente utilizado para a espacialização de variáveis ambientais, especialmente emissões atmosféricas (Shukla *et al.*, 2020; Bezyk *et al.*, 2021).

$$x_p = \frac{\sum_{i=1}^n \left(\frac{1}{d_i^2} \times x_i \right)}{\sum_{i=1}^n \frac{1}{d_i^2}} \quad (1)$$

Sendo:

x_p : Valor interpolado;

x_i : Valor de emissão do ponto i ;

d_i : Distância euclidiana entre o ponto interpolado e o ponto de emissão i ;

n : Número de pontos considerados na vizinhança.

A interpolação foi realizada considerando uma resolução espacial de 0,01 graus geográficos (aproximadamente 1136,9 metros), assegurando que o menor município brasileiro tivesse uma área totalmente representada. O sistema de coordenadas adotado foi WGS 1984, garantindo a compatibilidade com outras bases geoespaciais utilizadas na pesquisa.

Os valores interpolados foram então convertidos para o sistema de coordenadas Conica Equivalente de Albers Brasil, específico para o Brasil, garantindo a execução dos cálculos estatísticos processados por meio da ferramenta *Zonal Statistics*, no ArcMap, permitindo a extração dos valores médios de cada gás para cada município.

A partir desses valores, os dados foram organizados em planilhas tabulares, consolidando um banco de dados com a série temporal de emissões de GEE para todos os municípios brasileiros entre 1999 e 2023. Os valores foram extraídos na unidade original da plataforma e convertidos para toneladas de substância por quilômetro quadrado por ano (t/km²/ano).

Para permitir a comparação das emissões entre diferentes gases e facilitar a modelagem estatística, as emissões de CO₂ (fóssil e biológica), CH₄ e N₂O foram convertidas para CO_{2eq} (Equação 2), utilizando os coeficientes de Potencial de Aquecimento Global (GWP) de 100 anos, conforme o relatório AR6 do IPCC (IPCC, 2023).

$$CO_{2eq} = CO_{2fóssil} + CO_{2bio} + (GWP_{CH_4} \times CH_4) + (GWP_{N_2O} \times C_{N_2O}) \quad (2)$$

Os valores do GWP para 100 anos (GWP-100) são 273 ± 130 para óxido nitroso, $29,8 \pm 11$ para metano de origem fóssil e 27 ± 11 para metano de origem não fóssil (Forster *et al.*, 2021; IPCC, 2023). Como a plataforma EDGAR não disponibiliza as emissões de metano

separadas por origem, adotou-se o valor médio aritmético do GWP-100 para CH₄ ($28,4 \pm 11$) na Equação 2, garantindo maior precisão na conversão das emissões para CO_{2eq}. (Forster *et al.*, 2021; IPCC, 2023).

4.1.2 *Produto Interno Bruto per capita*

Os dados de PIB *per capita* municipal, em R\$/hab, foram adquiridos do IBGE e organizados para os 5570 municípios brasileiros, incluindo Brasília e o Distrito Estadual de Pernambuco, Fernando de Noronha.

Durante o processamento dos dados, foram identificadas lacunas na série temporal para 63 municípios, decorrentes da ausência de registros em função de suas respectivas datas de emancipação. Para verificar a viabilidade da inclusão dessas unidades na análise, foram consultadas as datas de fundação e emancipação dos municípios e comparadas com os anos para os quais os dados estavam indisponíveis.

Observou-se que esses municípios foram criados após 1999, o que explica a ausência de registros em anos anteriores. Dessa forma, os valores finais de PIB *per capita* utilizados na análise respeitam a disponibilidade de dados para cada município, conforme suas respectivas datas de criação.

4.1.3 *Densidade Demográfica*

A variável DD foi calculada com base na população estimada para cada município e na malha territorial municipal disponibilizada pelo IBGE. A população foi obtida a partir de estimativas anuais fornecidas pelo IBGE, considerando os anos censitários de 2000, 2010 e 2022, bem como a contagem populacional de 2007.

Durante a tabulação dos dados populacionais, foram identificadas inconsistências para determinados municípios emancipados recentemente, como Mojuí dos Campos (PA), Pescaria Brava (SC), Balneário Rincão (SC), Pinto Bandeira (RS) e Paraíso das Águas (MS), que não apresentavam registros para 2011.

Para solucionar essa questão, foi aplicada a metodologia de estimativa populacional utilizada pelo IBGE (2013), que considera a proporção da população dos municípios de origem antes da emancipação (Equação 3). Após essa estimativa, foi necessário subtrair os valores obtidos da população do município originário correspondente a cada área emancipada.

$$P_{est}(t) = \sum_{i=1}^n (a_i P_i(t) + b_i) \quad (3)$$

A população estimada $P_{est}(t)$ no momento t foi obtida a partir da soma das populações de n sub-regiões menores $P_i(t)$. Os coeficientes de variação foram determinados com base nos censos demográficos disponíveis, conforme Equações 4 e 5.

$$a_i = \frac{P_i(t_1) - P_i(t_0)}{P(t_1) - P(t_0)} \quad (4)$$

$$b_i = P_i(t_0) - a_i P(t_0) \quad (5)$$

Sendo:

a_i : Coeficiente de proporcionalidade do incremento da população;

b_i : Coeficiente linear de correção;

P_{est} : População estimada;

P_i : População do município i ;

P : População da unidade de federação;

t : Ano calculado;

t_0 : Censo 1;

t_1 : Censo 2.

Após o processamento dos dados populacionais e territoriais, a densidade demográfica, em hab/km², de cada município foi calculada (Equação 6) para todo o período analisado (IBGE, 2025).

$$DD = \frac{P_{mun}}{A_{mun}} \quad (6)$$

Sendo:

P_{mun} : População do município;

A_{mun} : Área total do município.

4.1.4 Índice de Urbanização

A determinação do IU foi realizada com base na área urbanizada dos municípios, obtida a partir dos dados de Uso e Cobertura da Terra (UCT) da plataforma MapBiomas Brasil – Coleção 9. Os dados tabuladores foram extraídos e, durante a organização da base de dados, identificaram-se valores nulos para 11 municípios. Para esses casos, verificaram-se as respectivas datas de fundação e emancipação, bem como registros populacionais, a fim de avaliar a viabilidade de reconstrução dos dados ausentes.

Para preencher as lacunas, foi realizada uma estimativa da área urbanizada por meio de imagens de sensoriamento remoto do satélite LANDSAT 7, que possui resolução multiespectral de 30 metros. No caso específico do município de Fernando de Noronha, observou-se, por meio de imagens do Google Earth Pro, que a área urbanizada permaneceu praticamente inalterada entre 1999 e 2023, sendo adotado um valor fixo (1,039 km²) para todos os anos analisados.

O índice de urbanização de cada município foi então calculado (Liu *et al.*, 2022) obedecendo a Equação 7.

$$IU = \frac{A_{urb}}{A_{mun}} \quad (7)$$

Sendo:

A_{urb} : Área urbanizada do município.

4.2 Estruturação e organização dos dados

Os dados ambientais, socioeconômicos e demográficos foram consolidados em uma estrutura tabular única para cada variável no Microsoft Excel (v.2502), abrangendo a série histórica dos municípios brasileiros no período de 1999 a 2023. Para garantir a integridade do conjunto de dados e minimizar potenciais inconsistências, foi realizada uma avaliação da completude das informações.

A presença de valores ausentes pode comprometer a integridade temporal e a robustez das análises estatísticas. A fim de solucionar esse problema, foi realizada uma verificação sistemática para identificar lacunas nos registros municipais das variáveis analisadas (CO₂ fóssil, CO₂ bio, CH₄ e N₂O, CO_{2eq}, PIB per capita, DD e IU). Foram considerados ausentes os dados não reportados para um município em um ou mais anos da série.

A verificação revelou que 63 dos 5.570 municípios brasileiros (1,13%) apresentavam registros incompletos ao longo do período avaliado. Essa ausência estava majoritariamente associada a municípios recém-criados, cujos dados não estavam disponíveis nos anos iniciais da série temporal.

Para preservar a consistência dos dados e evitar a introdução de vieses, optou-se pela exclusão desses municípios da análise. Essa decisão foi fundamentada na baixa representatividade dos casos omitidos e na necessidade de garantir homogeneidade na série temporal, evitando a imputação de valores ausentes que poderiam introduzir incertezas adicionais nas estimativas.

4.3 Análises exploratórias e estatísticas

4.3.1 Estatística descritiva

A estatística descritiva foi empregada para caracterizar quantitativamente a distribuição e evolução das variáveis analisadas ao longo do período de estudo, abrangendo CO_2 fóssil, CO_2 bio, CH_4 e N_2O , $\text{CO}_{2\text{eq}}$, PIB per capita, DD e IU. Essa abordagem permitiu a investigação da variabilidade das séries temporais e a identificação de padrões estruturais que poderiam influenciar as etapas subsequentes da modelagem.

Para cada variável, foram calculadas medidas de tendência central e dispersão, incluindo média, mediana, desvio padrão, valores mínimo e máximo, e coeficiente de variação (CV). Adicionalmente, foram calculadas as variações percentuais entre o primeiro e o último ano da série para destacar mudanças ao longo do tempo. A relação entre média e mediana foi utilizada como critério adicional para avaliar a presença de assimetrias na distribuição, auxiliando na detecção de possíveis distorções nos dados e na necessidade de transformações estatísticas.

Os cálculos foram realizados no ambiente *R* (R Core Team, 2024), permitindo a análise comparativa entre diferentes períodos, possibilitando a observação de tendências e a identificação de eventuais anomalias estatísticas.

4.3.2 Visualização gráfica

A representação gráfica foi utilizada como complemento às estatísticas descritivas para facilitar a interpretação das distribuições e tendências temporais das variáveis. Foram

gerados gráficos de dispersão (*jitter plot*) para visualizar a variação das observações individuais ao longo do tempo. Além disso, gráficos de tendência temporal foram construídos com a representação da média e da mediana ao longo do tempo, acompanhadas de uma faixa correspondente ao desvio padrão, possibilitando a identificação de flutuações e padrões de variabilidade interanual.

Para avaliar a distribuição dos dados antes e depois da aplicação de transformações estatísticas e remoção de outliers, foram gerados histogramas, permitindo verificar a presença de assimetria ou concentração excessiva dos valores em determinados intervalos.

O ambiente *RStudio* (Posit Team, 2023) foi empregado para a geração dos gráficos, utilizando o pacote *ggplot2* para manipulação e visualização de dados.

4.4 Tratamento estatístico das variáveis

A partir desta etapa, a análise estatística foi conduzida exclusivamente com base na variável agregada de emissões de $\text{CO}_{2\text{eq}}$, e as variáveis socioeconômicas PIB *per capita*, DD e IU. A opção metodológica por utilizar o $\text{CO}_{2\text{eq}}$, em vez de analisar separadamente os gases que o compõem (CO_2 fóssil, CO_2 bio, CH_4 e N_2O), fundamenta-se em obter uma medida integrada e padronizada de emissões, compatível com os indicadores socioeconômicos utilizados no modelo.

O $\text{CO}_{2\text{eq}}$ expressa a contribuição total dos diferentes gases de efeito estufa em termos de GWP, permitindo comparações diretas com variáveis explicativas contínuas e socialmente estruturadas. Essa agregação é particularmente relevante para análises estatísticas multivariadas, uma vez que facilita a interpretação dos resultados e evita problemas de redundância ou colinearidade entre gases com padrões parcialmente sobrepostos.

4.4.1 Tratamento de dados

A distribuição adequada das variáveis é um fator determinante para a aplicação de métodos estatísticos, especialmente em modelagens que assumem relações lineares ou distribuições específicas (Beale *et al.*, 2010; Cribari-Neto; Silva, 2011; Ghasemi Zahediasl, 2012). Dados com forte assimetria podem comprometer a interpretação dos coeficientes, a estabilidade das estimativas e a eficácia dos testes estatísticos (Beale *et al.*, 2010; Cribari-Neto; Silva, 2011; Ghasemi Zahediasl, 2012). Dessa forma, foi necessário aplicar transformações matemáticas às variáveis para aproximá-las de uma distribuição mais próxima de uma

distribuição simétrica e reduzir a influência de valores extremos, favorecendo a adequação dos modelos estatísticos subsequentes.

Dessa forma, foram aplicadas transformações matemáticas diretas nas variáveis analisadas, visando atenuar desvios de distribuição e melhorar a conformidade com pressupostos estatísticos. Para as variáveis CO_{2eq} , PIB_{per capita} e DD, foi adotada a transformação logarítmica natural. Já para o IU, cujos valores variavam entre 0 e 1, a aplicação do logaritmo não seria apropriada devido à presença de valores inferiores a 1. Dessa forma, optou-se pela transformação por raiz cúbica.

4.4.2 Detecção de outliers

O tratamento estatístico seguiu com a identificação de valores atípicos (*outliers*), um procedimento essencial para assegurar que as análises estatísticas não sejam indevidamente influenciadas por observações extremas. Para a detecção, foi adotado o método do Intervalo Interquartil (IQR), Equação 8, que não pressupõe normalidade dos dados e, portanto, é adequado para distribuições assimétricas. A partir do valor de IQR, os limites inferior e superior para identificação de valores atípicos foram definidos conforme as Equações 9 e 10.

$$IQR = Q_3 - Q_1 \quad (8)$$

$$Outlier inferior < Q_1 - 1,5 \times IQR \quad (9)$$

$$Outlier superior < Q_3 + 1,5 \times IQR \quad (10)$$

Sendo:

Q_1 : Primeiro quartil;

Q_3 : Terceiro quartil.

A detecção de outliers após a transformação dos dados garante que a influência de assimetrias seja reduzida antes da aplicação do critério interquartil, resultando em uma identificação mais precisa dos valores discrepantes (Ghasemi; Zahediasl, 2012). Esses valores

foram removidos da base de dados, buscando assegurar a coerência estatística das análises subsequentes e minimizar possíveis distorções na modelagem estatística.

4.4.3 *Teste de Normalidade*

A normalidade das variáveis foi avaliada por meio do teste de Anderson-Darling, aplicado individualmente para cada variável ao longo da série histórica, considerando um nível de significância de 5% ($\alpha=0,05$).

Inicialmente, o teste foi conduzido sobre os dados originais, permitindo a identificação de desvios da distribuição normal antes da aplicação de transformações matemáticas. Após a transformação das variáveis e remoção dos outliers identificados, o teste foi repetido para verificar possíveis melhorias na adequação dos dados à distribuição normal.

A análise gráfica de *Q-Q plots* foi utilizada como complemento ao teste estatístico em todas as etapas, permitindo a inspeção visual dos quantis empíricos em relação à distribuição normal teórica. Essa abordagem combinada assegurou uma avaliação mais robusta da distribuição das variáveis ao longo do processo de preparação dos dados.

4.5 **Avaliação da dependência estatística entre as variáveis**

4.5.1 *Correlação entre variáveis*

A relação entre as variáveis CO_{2eq}, PIB per capita, DD e IU foi avaliada por meio da correlação de Spearman, uma medida estatística não paramétrica que quantifica a associação monotônica entre variáveis. A correlação foi calculada considerando os valores médios e medianos das séries temporais, buscando identificar padrões estruturais na dependência estatística entre as variáveis.

A análise foi conduzida separadamente para as médias e medianas anuais de cada variável e as matrizes de correlação foram construídas a partir dos coeficientes de Spearman. A significância estatística dos coeficientes foi avaliada por meio de testes de hipótese bilaterais, associados à estatística de Spearman, com a obtenção dos respectivos p-valores.

Para complementar a interpretação dos coeficientes, foram geradas representações gráficas das matrizes de correlação, permitindo a visualização das relações estatísticas entre CO_{2eq}, PIB per capita, DD e IU.

4.5.2 *Análise de multicolinearidade*

A presença de multicolinearidade entre as variáveis independentes PIB_{per capita}, DD e IU foi avaliada por meio do Fator de Inflação da Variância (VIF), um indicador utilizado para quantificar o grau de redundância entre variáveis explicativas em modelos de regressão.

A interpretação dos valores obtidos seguiu critérios estatísticos estabelecidos para avaliação da multicolinearidade. Valores de VIF superiores a 10 indicam uma colinearidade forte, sugerindo a necessidade de ajustes no modelo, como a remoção de variáveis redundantes ou a reformulação da abordagem estatística. Já valores entre 5 e 10 representam uma colinearidade moderada, podendo impactar a precisão das estimativas dos coeficientes e exigindo uma avaliação criteriosa da estrutura do modelo. Valores inferiores a 5 indicam uma baixa multicolinearidade, considerada aceitável para aplicações estatísticas (Kim, 2019).

4.6 **Comparação Temporal das Variáveis**

4.6.1 *Avaliação da variabilidade temporal das variáveis*

A comparação temporal das variáveis foi conduzida utilizando o teste não paramétrico de Kruskal-Wallis, adequado para avaliar diferenças estatísticas entre distribuições ao longo do tempo na ausência de pressupostos de normalidade (Mckight; Najab, 2010; Gibbons; Chakraborti, 2014; Alibrandi, 2021). Esse teste foi aplicado separadamente para cada variável, com um nível de significância de 5%, permitindo identificar possíveis variações interanuais e auxiliar na estruturação da modelagem estatística subsequente.

Diante da detecção de diferenças estatisticamente significativas pelo teste de Kruskal-Wallis, foi empregado o teste de Dunn com correção de Bonferroni como procedimento *post-hoc*, possibilitando a identificação de quais pares de anos apresentavam diferenças significativas. As comparações foram categorizadas de acordo com o nível de significância estatística ($p < 0,05$; $p < 0,01$ e $p < 0,001$), permitindo a interpretação detalhada das variações interanuais nas variáveis analisadas.

4.6.2 *Análise de Autocorrelação Temporal*

Neste contexto, a Função de Autocorrelação (ACF) foi empregada como ferramenta diagnóstica fundamental para a identificação de padrões temporais nas variáveis, fornecendo

subsídios para a escolha das abordagens estatísticas subsequentes, especialmente no que tange à necessidade de incluir estruturas de dependência temporal, como efeitos aleatórios por ano ou correlação serial nos modelos mistos. Essa abordagem segue diretrizes amplamente adotadas na literatura estatística aplicada (Box *et al.*, 2015).

A estrutura temporal das variáveis foi investigada por meio da ACF, com o objetivo de verificar a presença de dependência temporal entre as observações. A análise foi conduzida separadamente para cada variável, permitindo avaliar a persistência de tendências e a influência de valores passados sobre as observações subsequentes.

Na análise de autocorrelação, foram considerados *lags* anuais, representando defasagens temporais sucessivas entre os valores das séries. Essa abordagem permitiu avaliar a influência de observações passadas sobre os valores atuais, ao longo do período de 1999 a 2023.

4.7 Modelagem estatística

4.7.1 Regressão linear múltipla (RLM; Multiple Linear Regression, MLR)

A RLM foi empregada como abordagem inicial para modelar a relação entre as emissões de CO_{2eq} e as variáveis explicativas IU, DD e PIB_{per capita}, conforme Equação 11. Esse método estatístico permite estimar a influência de múltiplos preditores sobre uma variável dependente, sob a suposição de linearidade entre as variáveis e homocedasticidade dos resíduos (Gujarati; Porter, 2009).

$$CO_{2eq} = \beta_0 + \beta_1 \cdot IU + \beta_2 \cdot DD + \beta_3 \cdot PIB_{per\ capita} + \varepsilon \quad (11)$$

Sendo:

β_0 : Intercepto;

$\beta_1, \beta_2, \beta_3$: Intercepto das variáveis explicativas;

ε : Erro residual.

Para a validação do modelo, foram calculadas métricas de desempenho como o coeficiente de determinação ajustado (R^2 ajustado) e o erro quadrático médio (RMSE), permitindo avaliar a capacidade preditiva e a precisão dos ajustes obtidos.

Entretanto, dada a possibilidade de heterocedasticidade nos resíduos, verificada por meio do teste de Breusch-Pagan, métodos alternativos de modelagem foram posteriormente empregados, visando maior coerência nos resultados.

4.7.2 Modelo linear generalizado (MLG; *Generalized Linear Model, GLM*)

Como alternativa à RLM, foi ajustado um MLG com distribuição normal e função de ligação identidade. Os MLGs oferecem maior flexibilidade ao permitir a suposição de normalidade estrita dos resíduos e adaptar a modelagem para diferentes distribuições da variável dependente, tornando-os adequados para cenários onde a estrutura dos dados pode apresentar desvios da linearidade ou da homoscedasticidade (Nelder; Wedderburn, 1972).

A distribuição gaussiana foi adotada devido à natureza contínua da variável resposta e à necessidade de avaliar um modelo que permitisse maior flexibilidade na presença de possíveis desvios da homocedasticidade observados na RLM (Dobson; Barnett, 2018). Para avaliar a qualidade do ajuste, foram calculadas as métricas pseudo- R^2 e o RMSE.

Embora o MLG compartilhe a mesma formulação da RLM ao adotar a distribuição normal e a função de ligação identidade, sua estrutura permite uma abordagem mais robusta ao incorporar potenciais variações na dispersão dos resíduos. A heterocedasticidade foi investigada por meio do teste de Breusch-Pagan e, com base nessa avaliação, foram exploradas metodologias estatísticas mais resilientes a variações na dispersão dos dados.

4.7.3 Regressão quantílica (RQ; *Quantile Regression, QR*)

Diante da presença de heterocedasticidade e possíveis assimetrias na distribuição de CO_{2eq} , a RQ foi empregada como uma abordagem complementar à modelagem estatística convencional.

Esse método permite modelar diferentes quantis da distribuição condicional, tornando-se mais robusta em cenários de variabilidade residual (Burmester *et al.*, 2025). Para este estudo, foi ajustado um modelo para a mediana ($\tau=0,5$), conforme Equação 12.

$$Q_{\tau}(CO_{2eq}|IU, DD, PIB_{per\ capita}) = \beta_0 + \beta_1 \cdot IU + \beta_2 \cdot DD + \beta_3 \cdot PIB_{per\ capita} \quad (12)$$

Sendo:

$Q_\tau(CO_{2eq}|IU, DD, PIB)$: Função quantílica condicional para um determinado quantil τ .

A principal vantagem da RQ é sua independência de pressupostos estritos sobre a distribuição dos resíduos, permitindo capturar relações heterogêneas entre as variáveis (Burmester *et al.*, 2025), não sendo então necessária a aplicação do teste de Breusch-Pagan. Para avaliar o desempenho do modelo, foram calculadas métricas como o pseudo- R^2 e o RMSE, garantindo a comparabilidade com os demais modelos ajustados.

4.7.4 Modelo misto linear (MLM; Linear Mixed Model, LMM)

Para considerar a dependência estrutural entre observações repetidas ao longo do tempo, foi ajustado um MLM, incorporando tanto efeitos fixos quanto efeitos aleatórios (Equação 13).

$$CO_{2eq_{ij}} = \beta_0 + \beta_1 \cdot IU_{ij} + \beta_2 \cdot DD_{ij} + \beta_3 \cdot PIB_{per\ capita_{ij}} + u_i + \varepsilon_{ij} \quad (13)$$

Sendo:

u_i : Efeito aleatório do município i ;

ε_{ij} : Erro residual específico de cada observação.

O modelo foi ajustado utilizando o método de Máxima Verossimilhança Restrita (REML), que fornece estimativas não viciadas dos componentes de variância. Dada a natureza dos dados, que apresentam variação na dispersão dos resíduos ao longo dos anos, foi empregada uma versão heterocedástica do modelo, permitindo que a variância residual (ε_{ij}) variasse entre os anos. Assim, a estrutura temporal foi incorporada por meio da heterocedasticidade dos resíduos, sem a necessidade da inclusão de um efeito aleatório específico para o ano.

A adequação do modelo foi avaliada por meio dos coeficientes de determinação R^2 , diferenciando-se entre o R^2 marginal, que reflete a variabilidade explicada apenas pelos efeitos fixos, e o R^2 condicional, que inclui também a variabilidade explicada pelos efeitos aleatórios. A inspeção dos resíduos foi realizada por meio de *QQ-plots* e gráficos de dispersão dos resíduos em relação aos valores ajustados, garantindo a adequação da estrutura adotada.

A escolha do modelo foi orientada pelos critérios de informação de Akaike (AIC) e Bayesiano (BIC). Como o BIC impõe uma penalização mais forte para modelos com maior

número de parâmetros, sua interpretação foi analisada em conjunto com o AIC para assegurar a parcimônia da modelagem sem comprometer a precisão preditiva.

4.8 Análise espacial das variáveis

Esta etapa, diferentemente da abordagem estatística multivariada, fora analisada o GEE em sua forma desagregada e agregada, considerando separadamente o CO₂ fóssil, CO₂ bio, CH₄ e N₂O, além do CO_{2eq}. Essa opção metodológica justifica-se pelas diferenças nas fontes setoriais e nos comportamentos espaciais de cada gás, cuja análise individual permite evidenciar padrões territoriais específicos que não seriam perceptíveis na medida agregada. Além das variáveis ambientais, também foram considerados os indicadores socioeconômicos.

4.8.1 Índice de Moran Global

Para a realização da análise de autocorrelação espacial global, as variáveis ambientais, socioeconômicas e demográficas foram previamente espacializadas por meio da vinculação de suas respectivas bases de dados à malha municipal oficial do Brasil. Essa associação foi realizada utilizando-se como identificador o código IBGE do município, com a projeção cartográfica definida no sistema Cônica Equivalente de Albers Brasil, adequado para a representação de dados em grandes extensões territoriais.

A análise de autocorrelação espacial foi conduzida com base no GISA, uma medida que avalia a correlação entre os valores de uma variável em uma unidade espacial e os valores dessa mesma variável nas unidades vizinhas. Para isso, foi construída uma matriz de vizinhança do tipo *rook contiguity* (contiguidade por borda), sem padronização. Essa abordagem considera como vizinhos os municípios que compartilham arestas, desconsiderando apenas conexões por vértices (Anselin; Syabri; Kho, 2009).

Dado o método de contiguidade adotado, foram excluídos da análise os municípios que não possuem vizinhos contíguos dentro da malha municipal, como Fernando de Noronha (PE) e Ilhabela (SP), a fim de evitar distorções estatísticas.

A Equação 14 representa o GISA (Silva *et al.*, 2014; Silva *et al.*, 2021; Luzardo; Castañeda Filho; Rubim, 2017), em que GISA varia entre -1 e +1, sendo que valores variando de >0 a +1 indicam autocorrelação espacial positiva, caracterizando a presença de *clusters* de municípios com valores semelhantes da variável analisada. Valores variando de <0 a -1 indicam autocorrelação negativa, sugerindo padrões de dispersão, enquanto valores próximos de zero

indicam uma distribuição aleatória (Luzardo; Castañeda Filho; Rubim, 2017; Sumunar; Arif; Khotimah, 2021).

$$GISA = \frac{n}{\sum_{i=1}^n \sum_{j=1}^n w_{ij}} \frac{\sum_{i=1}^n \sum_{j=1}^n w_{ij} (y_i - \bar{y})(y_j - \bar{y})}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad \text{para } i \neq j \quad (14)$$

Sendo:

GISA: Índice de Moran Global;

n : Número correspondente de municípios;

y_i : Valor do atributo considerado no município i ;

y_j : Valor do atributo considerado no município j ;

$\bar{y}$: Valor médio do atributo na região de estudo;

w_{ij} : Pesos atribuídos conforme a conexão entre as áreas i e j .

Para cada cálculo anual do GISA, foram considerados os valores observados do índice, bem como o valor esperado sob a hipótese nula, a variância associada, o z-score correspondente e o p-valor de significância estatística. O valor esperado reflete a média teórica do índice na ausência de autocorrelação espacial; a variância expressa a dispersão dos valores em torno do valor esperado; o z-score indica a magnitude do desvio do valor observado em relação ao esperado, em unidades de desvio padrão; e o p-valor representa a probabilidade de o resultado observado ocorrer sob a hipótese nula, sendo considerados estatisticamente significativos os valores inferiores a 0,05 (Chen, 2021; Li; Wu; Wu, 2022).

4.8.2 Índice de Moran Local

A análise da autocorrelação espacial local foi conduzida por meio do cálculo do LISA (Equação 15) (Silva *et al.*, 2014; Silva *et al.*, 2021; Luzardo; Castañeda Filho; Rubim, 2017), cujo objetivo é identificar agrupamentos estatisticamente significativos (*clusters*) e *outliers* espaciais a partir da comparação entre os valores de cada unidade espacial e os de seus vizinhos imediatos. Esse método permite a classificação dos municípios em cinco categorias: Alto-Alto (AA) e Baixo-Baixo (BB), indicando a presença de *clusters* espaciais de alta e baixa

magnitude, respectivamente; Alto-Baixo (AB) e Baixo-Alto (BA), que representam *outliers* espaciais; e Não Significativo (NS), quando não há autocorrelação espacial detectada.

$$LISA = \frac{(y_i - \bar{y}) \sum_{j=1}^n w_{ij} (y_j - \bar{y})}{\frac{\sum_{i=1}^n (y_i - \bar{y})^2}{n}} \quad (15)$$

Sendo:

LISA: Índice de Moran Local.

As categorias de agrupamento do LISA são classificadas diante dos resultantes da relação entre os valores da variável na unidade e em seus vizinhos. Os agrupamentos AA indicam municípios com valores elevados da variável analisada cercados por vizinhos também com valores elevados, configurando um *cluster* de altas concentrações. De forma análoga, BB representa agrupamentos de municípios com baixos valores da variável, próximos de outros igualmente baixos, indicando *clusters* de baixa intensidade. Já os padrões AB e BA representam áreas de transição, caracterizadas pela discrepância entre o valor da unidade e a média de seus vizinhos. O padrão AB ocorre quando um município apresenta valor acima da média cercado por vizinhos com valores abaixo da média, enquanto BA corresponde a municípios com valores inferiores à média inseridos em contextos de alta intensidade do atributo analisado (Luzardo; Castañeda Filho; Rubim, 2017).

Para garantir maior robustez estatística aos resultados, foi adotado o procedimento de 9.999 permutações aleatórias, o que permite calcular de forma mais precisa o p-valor associado a cada observação, comparando o valor observado com uma distribuição nula gerada a partir da aleatorização dos dados (Zhu *et al.*, 2022; Dabuo; Madzikanda; Coulibaly, 2023).

A aplicação do LISA foi realizada exclusivamente para os anos que apresentaram os valores extremos do GISA — ou seja, o ano com menor e o ano com maior autocorrelação espacial para cada variável analisada. Essa abordagem possibilitou evidenciar os contrastes espaciais mais relevantes do período.

Adicionalmente, foram elaborados mapas representando a espacialidade dos municípios que apresentaram significância estatística ($p\text{-valor} \leq 0,05$) na análise local. Esses mapas foram construídos com o intuito de facilitar a visualização dos agrupamentos espaciais mais relevantes e destacar as áreas onde os padrões de associação espacial se mostraram estatisticamente consistentes (Anselin; Syabri; Kho, 2009).

5 RESULTADOS

5.1 Caracterização descritiva e padrões de distribuição das variáveis

A estatística descritiva das variáveis de gases desagregados está apresentada na Tabela 1. O CO₂ fóssil apresentou média de 17.793,0 t/km² e mediana de 4.911,4 t/km², com a menor variação percentual no período (28,6%). O CO₂ bio destacou-se com a maior média (29.875,4 ton/km²) e a maior variação relativa do período (82,0%). O CH₄ apresentou o maior coeficiente de variação (1.658,9%), com média de 777,9 t/km² e crescimento de 34,7%. O N₂O, embora tenha os menores valores absolutos (média=11,8 t/km²), apresentou crescimento de 36,8% e CV de 257,0%, revelando também elevada variação espacial relativa. Todas as variáveis apresentaram expressiva dispersão (CV>250%), evidenciando acentuada heterogeneidade nas emissões. Os quartis indicam distribuições assimétricas positivas, com medianas deslocadas em direção ao Q1 e valores máximos elevados, evidenciando concentração das emissões em poucos municípios.

Tabela 1 - Estatísticas descritivas das variáveis de emissão de GEE

Parâmetros	CO ₂ fóssil	CO ₂ bio	CH ₄	N ₂ O
Mínimo	12,7	5,7	0,03	0,2
Q1	2.297,3	2.237,2	72,6	4,9
Mediana	4.911,4	6.628,6	143,0	8,9
Q3	9.431,3	20.327,8	253,9	13,8
Máximo	3.321.020,2	2.856.832,4	736.986,9	3.683,6
Média	17.793,0	29.875,4	777,9	11,8
Desvio-padrão	77.058,2	98.286,4	12.905,5	30,3
CV	433,1%	329,0%	1.658,9%	257,0%
Variação percentual do período	28,6%	82,0%	34,7%	36,8%

Fonte: Elaborado pelo autor (2024).

As variáveis ambientais agregadas e os indicadores socioeconômicos e demográfico, apresentados na Tabela 2, evidenciam distintos padrões de dispersão e crescimento ao longo do período analisado. A média das emissões de CO_{2eq} foi de 72.978,2 t/km², com um desvio padrão elevado (417.085,4), indicando alta dispersão entre os municípios. O CV reforça essa heterogeneidade, atingindo 571,5%. O PIB per capita apresentou um crescimento expressivo de 995,4% no período, com média de 16.047,8 R\$/hab e CV menor

(143,7%), sugerindo menor dispersão relativa em comparação com as demais variáveis. Já a DD variou entre 0,03 e 14.593,5 hab/km² (CV=529,0%) e IU apresentou crescimento de 63,0% no período, variando de 7e-7 a 0,999 (CV=374,3%). Os quartis indicam distribuições assimétricas positivas, com medianas próximas ao Q1 e valores máximos elevados, refletindo elevada heterogeneidade espacial entre os municípios.

Tabela 2 - Estatísticas descritivas das variáveis ambiental agregada, socioeconômicas e demográfica

Parâmetros	CO2eq	PIB	DD	IU
Mínimo	97,6	301,6	0,03	0,0000007
Q1	9.040,1	4.864,3	11,6	0,001
Mediana	19.000,4	9.587,4	24,5	0,003
Q3	42.425,8	19.200,4	52,6	0,008
Máximo	21.154.186,2	920.834,0	14.593,5	0,999
Média	72.978,2	16.047,8	110,5	0,016
Desvio-padrão	417.085,4	23.054,1	584,7	0,061
CV	571,5%	143,7%	529,0%	374,3%
Variação percentual do período	50,1%	995,4%	24,6%	63,0%


Fonte: Elaborado pelo autor (2024).

Observa-se que todas as variáveis apresentaram um aumento ao longo do período analisado, com diferentes graus de variabilidade.

A Figura 1 exibe a dispersão das emissões dos GEE em todos os municípios brasileiros entre 1999 e 2023. As emissões de CO₂ fóssil (Figura 1a) concentram-se predominantemente na faixa de até 250.000 t/km², porém com registro de valores superiores a 3.000.000 t/km² ao longo de todo o período. O CO₂ bio (Figura 1b) apresenta distribuição semelhante, porém com registros que inferiores à 3.000.000 t/km². As emissões de CH₄ (Figura 1c) mostram forte assimetria, com valores muito concentrados na faixa de até 50.000 t/km² e pontuais municípios com emissões superiores a 300.000 t/km² ao longo de todo o período, o que evidencia uma elevada heterogeneidade temporal, em consonância com o CV apresentado na Tabela 1.

Por fim, as emissões de N₂O (Figura 1d) revelam menor magnitude relativa em comparação aos demais gases, com valores majoritariamente inferiores a 250 t/km², embora com picos isolados que ultrapassam 3.500 t/km² nos primeiros três anos da série, sugerindo emissões intensas em contextos localizados e específicos.

Figura 1 - Dispersão dos valores das variáveis de emissão de GEE nos municípios ao longo do período analisado




Fonte: Elaborado pelo autor (2024).

Legenda: (a) CO₂ fóssil, (b) CO₂ bio, (c) CH₄ e (d) N₂O.

A dispersão das variáveis ambiental agregada, socioeconômicas e demográfica (Figura 2) nota-se a grande variação nas emissões de CO_{2eq} (Figura 2a), com valores concentrados na faixa de 0 e 2.000.000 t/km², porém com a presença de valores extremamente elevados em alguns municípios. O PIB per capita (Figura 2b) exibe um crescimento acentuado, apresentando maior concentração na faixa de 0 a 100.000 R\$/hab. A DD (Figura 2c) apresenta uma distribuição mais estável, enquanto o IU (Figura 2d) exibe uma concentração de valores próximos a 0, evidenciando municípios com baixa urbanização.

Figura 2 - Dispersão dos valores das variáveis ambiental agregada, socioeconômicas e demográfica nos municípios ao longo do período analisado



Fonte: Elaborado pelo autor (2025).


Legenda: (a) CO₂eq, (b) PIB per capita, (c) DD e (d) IU.

Os gráficos de tendência temporal (Figura 3) ilustram a evolução da média, mediana e desvio-padrão das variáveis ao longo dos anos para as emissões de GEE. Observa-se que para todas as variáveis (Figura 3a, 3b, 3c e 3d), mantiveram estabilidade relativa na média e na mediana, com variações marginais crescentes, com o CO₂ bio (Figura 3b) apresentando maior variação de média no período.

Em relação ao desvio padrão, o CO₂ fóssil (Figura 3a) apresentou oscilações durante o período, porém ainda elevados, indicando elevada heterogeneidade espacial das emissões entre os municípios. Para o CO₂ bio (Figura 3b), observa-se um crescimento contínuo do desvio padrão de 2000 a 2005, seguindo de pequenas oscilações até o fim do período, refletindo crescimento das emissões em municípios específicos e aumento da desigualdade espacial dessas emissões. Para o CH₄ (Figura 3c), apresentou leve ampliação da dispersão nos anos mais recentes. Já para o N₂O (Figura 3d), os três primeiros anos (1999 a 2001) apresentou um desvio

padrão acentuado, o que confirma sua menor magnitude e menor variabilidade territorial, seguido de uma estabilidade até o final do período.

Figura 3 - Variação temporal variáveis de emissão de GEE considerando estatísticas de tendência central e dispersão




Fonte: Elaborado pelo autor (2024).

Legenda: (a) CO₂ fóssil, (b) CO₂ bio, (c) CH₄ e (d) N₂O.

A tendência temporal para as variáveis ambiental agregada, socioeconômicas e demográfica (Figura 4) ilustram a evolução da média, mediana e desvio padrão das variáveis ao longo dos anos para as emissões de GEE. A média das emissões de CO_{2eq}, DD e IU permanece superior à mediana durante todo o período (Figura 4a, 4c e 4d), sugerindo uma distribuição assimétrica e influenciada por valores extremamente elevados, enquanto o PIB per capita (Figura 4b) apresentam menor discrepância entre média e mediana nos primeiros anos, indicando distribuições menos assimétricas nessa faixa.

Figura 4 - Variação temporal das variáveis ambiental agregada, socioeconômicas e demográfica considerando estatísticas de tendência central e dispersão




Fonte: Elaborado pelo autor (2025).

Legenda: (a) CO_{2eq}, (b) PIB per capita, (c) DD e (d) IU.

5.2 Adequação estatística dos dados e detecção de outliers

A assimetria na distribuição das variáveis é corroborada pelos histogramas (Figura 5), onde se observa a concentração de valores próximos ao limite inferior da distribuição. Esse comportamento é evidente para todas as variáveis, destacando a presença de caudas longas.

Figura 5 - Histogramas da distribuição dos valores das variáveis nos municípios brasileiros




Fonte: Elaborado pelo autor (2025).

Legenda: (a) CO_{2eq}, (b) PIB per capita, (c) DD e (d) IU.

O teste de normalidade de Anderson-Darling revelou que as variáveis apresentavam distribuições significativamente desviadas da normalidade ($p < 0,000$) antes da transformação dos dados, evidência complementada pela análise visual dos gráficos *Q-Q* (Figura 6).

Figura 6 - Gráficos $Q-Q$ das variáveis analisadas antes da transformação dos dados



Fonte: Elaborado pelo autor (2025).

Legenda: (a) CO_{2eq} , (b) PIB per capita, (c) DD e (d) IU.


Observa-se na Figura 6 que todas as variáveis exibem desvios substanciais da normalidade, especialmente nas caudas das distribuições, conforme evidenciado pela discrepância dos quantis empíricos em relação à linha de referência teórica. Esse comportamento é indicativo de distribuições assimétricas com a presença de valores extremos. Assim, a necessidade de transformação dos dados para melhorar a aderência à normalidade foi confirmada.

Após a aplicação das transformações matemáticas, identificou-se a presença de municípios com valores atípicos ao longo da série temporal. A variável PIB per capita apresentou 118 municípios classificados como outliers (2,1%), enquanto o IU exibiu 457 municípios (8,3%). Para a DD, 227 municípios (4,1%) foram identificados como valores extremos, e para as emissões de CO_{2eq} , 280 municípios (5,1%) foram classificados como outliers.

No total, considerando a sobreposição entre as variáveis, 674 municípios (12,2%) apresentaram pelo menos um valor atípico e foram removidos da análise subsequente, garantindo maior robustez aos modelos estatísticos aplicados.

A Figura 7 apresenta os histogramas das variáveis após a transformação e remoção de outliers, permitindo uma comparação com as distribuições originais (Figura 5). Visualmente, observa-se uma redistribuição dos valores, reduzindo a concentração de dados próximos ao limite inferior e atenuando caudas longas.

Figura 7 - Histogramas da distribuição dos valores após a transformação matemática e remoção dos outliers das variáveis nos municípios brasileiros




Fonte: Elaborado pelo autor (2025).

Legenda: (a) CO_{2eq}, (b) PIB per capita, (c) DD e (d) IU.

Mesmo após a transformação e a remoção de outliers, as variáveis permaneceram significativamente desviadas da normalidade ($p < 0,002$), para todos os anos de cada variável, indicando que as distribuições das variáveis ainda apresentam características que não seguem a distribuição normal, reforçando a necessidade de abordagens estatísticas robustas para a modelagem subsequente.

Por fim, a Figura 8 apresenta os gráficos $Q-Q$ para as variáveis após a transformação e remoção de outliers, permitindo, através da análise visual, avaliar a aderência dos dados transformados à distribuição normal teórica, complementando as evidências estatísticas fornecidas pelo teste de Anderson-Darling.

Figura 8 - Gráficos $Q-Q$ das variáveis analisadas depois da transformação matemática e remoção dos outliers



Fonte: Elaborado pelo autor (2025).


Legenda: (a) CO_{2eq}, (b) PIB per capita, (c) DD e (d) IU.

Nos gráficos $Q-Q$ observou-se um alinhamento mais próximo dos quantis empíricos com a reta teórica (Figura 8), indicando uma melhora na distribuição dos dados, ainda que desvios persistam nas caudas.

5.3 Análise de dependência linear e multicolinearidade entre preditores

A relação estatística entre as variáveis avaliada por meio do coeficiente de correlação de Spearman, considerando as medidas de tendência central (média e mediana) é apresentada na Figura 9.

Figura 9 - Matriz de correlação de Spearman



Fonte: Elaborado pelo autor (2025).

Legenda: (a) Média e (b) Mediana.


Os resultados evidenciam uma forte correlação positiva e significativa ($p < 0,001$) entre o IU e a DD, com coeficientes de 0,81 para médias e medianas. Da mesma forma, observou-se uma correlação positiva moderada entre IU e CO_{2eq} (0,68 para médias e medianas). A relação entre PIB _{per capita} e emissões de CO_{2eq} também foi significativa ($p < 0,001$), com coeficientes de 0,52 para médias e 0,51 para medianas.

Por outro lado, não foi identificada uma relação estatisticamente significativa entre DD e PIB _{per capita} ($p = 0,085$ para médias e $p = 0,435$ para medianas), com coeficientes próximos de zero (-0,02 para médias e -0,01 para medianas).

De maneira geral, os valores de correlação obtidos para médias e medianas foram bastante semelhantes, indicando que a escolha da métrica de tendência central não afetou significativamente a interpretação das relações entre as variáveis. Além disso, as correlações altamente significativas ($p < 0,001$) reforçam a consistência estatística das associações entre as variáveis.

Já a avaliação de redundância entre as variáveis preditoras (PIB _{per capita}, DD e IU) investigada por meio do VIF, indicou que nenhuma variável apresentou VIF superior a 5, sugerindo que não há um problema crítico de multicolinearidade que comprometa a estabilidade dos coeficientes estimados nos modelos estatísticos.

Os valores encontrados foram 4,22 para o IU, 3,82 para a DD e 1,51 para o PIB _{per capita}, estando todos dentro da faixa considerada aceitável na literatura ($VIF < 5$). Dessa forma, não foi necessária a remoção de variáveis do modelo neste estágio da análise, permitindo a



Fonte: Elaborado pelo autor (2025).


Legenda: ▲ (triângulo roxo) = $p < 0,001$, ■ (quadrado azul) = $p < 0,01$, e ● (círculo verde) = $p < 0,05$.

Os resultados evidenciam que não houve diferenças estatisticamente significativas entre os anos de 1999 e 2000 para nenhuma variável. De modo geral, verificou-se um padrão em que os anos iniciais apresentam menor número de diferenças significativas (quadrado azul e círculo verde), enquanto os anos intermediários e finais mostram maior variação (triângulo roxo).

Observa-se que a variável PIB _{per capita} se destacou ao apresentar diferenças significativas altas ($p < 0,001$) para praticamente todos os anos analisados. Para as emissões de CO_{2eq}, os anos mais recentes (2014, 2015, 2017, 2019 e 2020) demonstraram menor diferença estatística entre si, indicando uma possível estabilização da variável nesses períodos. O IU apresentou um comportamento similar, com menor variação estatística nos anos 2017 a 2020. Já a DD exibiu diferenças estatísticas nos anos iniciais do período analisado (1999-2003), com predominância de significância de valor de $p < 0,05$.

A análise da persistência temporal das variáveis com ACF permitiu identificar a influência de valores passados sobre os valores presentes e a possível presença de dependência temporal, conforme Figura 10.

Figura 10 - Estrutura de dependência temporal identificada pela ACF



Fonte: Elaborado pelo autor (2025).

Legenda: (a) CO_{2eq}, (b) PIB _{per capita}, (c) DD e (d) IU.

Os resultados indicam que todas as variáveis apresentaram correlação positiva significativa ($p < 0,05$) nos primeiros quatro *lags* (*lags* de curto prazo), com redução gradual da dependência temporal ao longo do tempo, exibindo um padrão de autocorrelação positivo não significativo até o *lag* 8 (*lags* de médio prazo), indicando que os valores permanecem

moderadamente influenciados por registros de até oito anos anteriores, e inversão nos *lags* subsequentes.

Para a DD e o IU, observou-se ainda uma correlação negativa significativa ($p < 0,05$) nos *lags* 14 a 16 (*lags* de longo prazo), sugerindo uma inversão de tendência ao longo do tempo, voltando para valores não significativos nos anos seguintes, caracterizado por um processo de estabilização.

A persistência da autocorrelação nos primeiros *lags* reforça a presença de estruturas temporais nos dados, evidenciando que as condições passadas influenciam os valores futuros no curto prazo. Esse comportamento é particularmente relevante para modelagens estatísticas que permitem avaliar tanto a relação média entre as variáveis quanto os efeitos em diferentes partes da distribuição, além de considerar possíveis dependências temporais e heterogeneidades nos dados.

5.5 Modelagem estatística das emissões de CO_{2eq}

5.5.1 RLM

O modelo da RLM indicou que 56,75% da variabilidade nas emissões de CO_{2eq} é explicada pelo conjunto de variáveis independentes consideradas (R^2 ajustado=0,5675).

Os coeficientes estimados indicam que todas as variáveis explicativas possuem uma associação positiva significativa ($p < 0,001$) com as emissões de CO_{2eq}. Conforme Equação 16, o IU teve o maior coeficiente entre as variáveis (2,844), evidenciando sua forte relação com o aumento das emissões, enquanto o coeficiente de DD e PIB_{per capita} com menor valor, implicando em uma menor relação proporcional as emissões de CO_{2eq}. O termo ε (erro residual) não é representado por um valor fixo, pois ele corresponde às variações não explicadas pelo modelo.

$$CO_{2eq} = 3,915 + 2,844 \cdot IU + 0,517 \cdot DD + 0,419 \cdot PIB + \varepsilon \quad (16)$$

A análise dos resíduos revelou uma distribuição simétrica, evidenciado pelo teste de Breusch-Pagan, indicando a presença de heterocedasticidade significativa ($p < 0,001$) nos resíduos, ou seja, uma variância não constante ao longo das previsões do modelo.

O RMSE foi de 0,673, refletindo o desvio médio das previsões em relação aos valores observados. Esses resultados sugerem que, embora o modelo explique uma parcela substancial da variação das emissões de CO_{2eq}, há indícios de heterogeneidade na dispersão dos

resíduos, o que pode impactar a confiabilidade das inferências estatísticas. Modelos estatísticos mais robustos podem ser necessários para lidar com essa característica dos dados.

5.5.2 MLG

Os coeficientes estimados do MLG apresentaram magnitudes distintas em relação aos obtidos na RLM, embora tenham mantido associação positiva e estatisticamente significativa ($p < 0,001$) entre as variáveis explicativas e as emissões de CO_{2eq} . Os coeficientes estimados para o PIB _{per capita} (0,044), IU (0,240) e DD (0,056) indicam efeitos proporcionais sobre a média das emissões, refletindo a natureza multiplicativa do modelo com função de ligação logarítmica, apresentado na Equação 17.

$$CO_{2eq} = 1,660 + 0,240 \cdot IU + 0,056 \cdot DD + 0,044 \cdot PIB + \varepsilon \quad (17)$$

O pseudo R^2 (0,5675) foi equivalente ao R^2 ajustado da RLM, sugerindo que o modelo MLG não apresentou uma melhora substancial na explicação da variabilidade dos dados, mantendo a mesma capacidade preditiva. Além disso, o RMSE reduziu em relação ao modelo linear, indicando melhora no ajuste médio das previsões às observações, particularmente diante da maior assimetria e variabilidade presente na série temporal completa.

A heterocedasticidade foi confirmada pelo teste de Breusch-Pagan ($p < 0,001$), reforçando a presença de variância não constante dos resíduos, o que sugere a avaliação de alternativas estatísticas mais flexíveis para capturar melhor as variações estruturais nos dados.

5.5.3 RQ

A RQ, útil para lidar com a heterogeneidade dos dados, apresentou coeficientes estimados para PIB _{per capita} (0,432), IU (3,403) e DD (0,476) positivos e estatisticamente significativos ($p < 0,001$) na explicação das emissões de CO_{2eq} (Equação 18). Em comparação com os modelos anteriores, a RQ apresentou um coeficiente maior para IU, sugerindo um efeito mais pronunciado dessa variável na mediana da distribuição das emissões.

$$Q_{0,5}(CO_{2eq}|IU, DD, PIB) = 3,820 + 3,403 \cdot IU + 0,476 \cdot DD + 0,432 \cdot PIB \quad (18)$$

A avaliação do ajuste do modelo revelou um pseudo R^2 de 0,5663, próximo ao valor obtido na RLM e no MLG, indicando que a variabilidade explicada permaneceu similar. No entanto, o RMSE foi ligeiramente superior aos valores obtidos nos modelos anteriores (0,674), sugerindo que a RQ pode oferecer vantagens interpretativas para diferentes quantis, mas sem ganhos substanciais na predição global do fenômeno analisado.

Dado que a RQ não impõe restrições rígidas sobre a distribuição dos resíduos, esse modelo reforça a importância da exploração de diferentes pontos da distribuição condicional, permitindo inferências mais abrangente sobre os impactos das variáveis explicativas. Dessa forma, a adoção desse modelo amplia a interpretação estatística ao oferecer um panorama mais abrangente da relação entre as variáveis analisadas e as emissões de CO_{2eq} .

5.5.4 MLM

O modelo MLM demonstrou um ajuste adequado, conforme evidenciado pelos valores do AIC (-230766,5) e do BIC (-230475,5), além do *log-likelihood* elevado (115413,3). Os coeficientes estimados indicaram relações positivas entre PIB _{per capita} (0,168), IU (2,247) e DD (0,202) com as emissões de CO_{2eq} , sendo todas as variáveis estatisticamente significativas ($p < 0,0001$).

A modelagem da heterocedasticidade, que incluí os efeitos aleatórios, permitiu capturar variações municipais, com um desvio-padrão associado de 0,802, refletindo diferenças substanciais entre os municípios, enquanto o desvio-padrão residual foi de 0,162. Representando-a na Equação 19, com u representando a variabilidade entre os municípios $u_i \sim N(0, 0,802^2)$ e ε_{ij} capturando a mudança da variabilidade ao longo dos anos ($\varepsilon_{ij} \sim N(0, \sigma_{ano}^2)$).

$$CO_{2eq_{ij}} = 7,014 + 2,247 \cdot IU_{ij} + 0,202 \cdot DD_{ij} + 0,168 \cdot PIB_{ij} + u_i + \varepsilon_{ij} \quad (19)$$

A modelagem MLM evidenciou variação temporal do desvio-padrão residual, com redução progressiva da dispersão ao longo dos anos iniciais da série. Os menores níveis de variabilidade residual concentraram-se no período entre 2010 e 2015 (0,041 – 0,055), atingindo o valor mínimo em 2015. A partir desse intervalo, observou-se uma reversão do padrão, com aumento gradual da heterocedasticidade residual, alcançando 0,130 em 2023.

A avaliação do ajuste do modelo revelou um R^2 marginal de 0,162, indicando que os efeitos fixos explicam 16,2% da variabilidade das emissões. Entretanto, o R^2 condicional foi de 0,967 (96,7%), evidenciando que a maior parte da variabilidade nos dados é capturada pelos efeitos aleatórios, ou seja, as diferenças entre municípios e variações ao longo dos anos desempenham um papel predominante na explicação das emissões.

A discrepância entre os valores de R^2 marginal e condicional reforça a importância de considerar essas estruturas hierárquicas na modelagem, demonstrando que abordagens que desconsideram tais efeitos podem subestimar a complexidade dos padrões observados.


Os resultados confirmam que o modelo de efeitos mistos com variância residual diferenciada ao longo do tempo foi adequado para capturar a estrutura dos dados, proporcionando uma modelagem mais realista das emissões de $\text{CO}_{2\text{eq}}$ nos municípios brasileiros.

5.6 Autocorrelação espacial global

5.6.1 Emissões de GEE

Ao longo do período, os valores GISA (Figura 11) revelam padrões consistentes de autocorrelação espacial positiva nas emissões dos GEE (CO_2 fóssil, CO_2 bio, CH_4 e N_2O), bem como na variável agregada $\text{CO}_{2\text{eq}}$. Dentre os gases analisados, o CO_2 fóssil manteve autocorrelação crescente ao longo dos anos, com variação entre 0,370180 (2004) e 0,478386 (2016). O CO_2 bio apresentou os maiores níveis de agrupamento espacial, atingindo seu pico em 2016 (0,583623) e menor valor em 2000 (0,496347).

Figura 11 - Evolução do GISA para os GEE e CO_{2eq} nos municípios brasileiros entre 1999 e 2023



Fonte: Elaborado pelo autor (2025).

Legenda: ▲ = menor GISA e ▲ = maior GISA da variável.


No caso do N₂O, observa-se comportamento mais homogêneo, com valores mais elevados nos últimos anos, com pico em 2016 (0,512164), enquanto o CH₄ exibiu os menores níveis de autocorrelação, com destaque em 2014 (0,237889) e concentração um pouco mais pronunciada em 2008 (0,312898). A variável CO_{2eq}, por sua vez, apresentou comportamento muito semelhante ao CH₄, porém com maiores valores, com leve oscilação entre 0,308563 (2014) e 0,362502 (2010), refletindo a combinação das dinâmicas espaciais individuais dos gases.

Todos os anos analisados para os GEE apresentaram z-score superior a 2,58 (p-valor>0,01), indicando forte evidência contra a hipótese nula de aleatoriedade espacial. Esses resultados confirmam a presença persistente de autocorrelação espacial positiva ao longo de todo o período analisado. A análise da variância das variáveis indicara uma baixa variância para os GEE (CO_{2 fóssil}=0,000061; CO_{2 bio}=0,000061; CH₄=0,000044; N₂O=0,000059 e CO_{2eq}=0,000052), indicando variações relativamente homogêneas entre os anos e baixo risco de flutuações aleatórias nos valores de GISA sendo maior deles representado pelo CO_{2 fóssil} e CO_{2 bio}.

5.6.2 Indicadores socioeconômicos e demográficos

A Figura 12 evidencia a evolução do GISA para os indicadores socioeconômicos e demográfico nos municípios brasileiros ao longo de 25 anos. O IU apresentou os maiores níveis de autocorrelação espacial em todo o período, com valores variando de 0,450439 (1999) a 0,486798 (2023). A DD também exibiu padrões consistentes, com leve oscilação entre 0,426906 (1999) e 0,460998 (2022). Já o PIB _{per capita}, apesar de manter autocorrelação positiva ao longo dos anos, mostrou maior variabilidade, com o menor GISA registrado em 2011 (0,253622) e o maior em 2016 (0,385620), refletindo uma dinâmica mais volátil.

Figura 12 - Evolução do GISA para os indicadores socioeconômicos nos municípios brasileiros entre 1999 e 2023



Fonte: Elaborado pelo autor (2025).
Legenda: ▲ = menor GISA e ▲ = maior GISA por variável.


Os valores de variância se mantiveram baixos ao longo da série histórica, com PIB _{per capita} e IU com variância de 0,000062, e DD com variância de 0,000060. Além disso, todos os anos analisados apresentaram valores de z-score > 2,58, indicando autocorrelação espacial estatisticamente significativa (p-valor > 0,01).

5.7 Autocorrelação espacial local

5.7.1 Emissões de GEE

A Figura 13 apresenta os resultados da autocorrelação espacial local para as emissões de CO₂ de origem fóssil. Em ambos os anos, de menor (Figura 13a) e maior GISA (Figura 13b), observa-se predominância da classe NS (>68% dos municípios), o que evidencia a baixa autocorrelação local para a maior parte do território. Em ambos os anos são marcados por *cluster* AA concentrados principalmente em áreas litorâneas e regiões metropolitanas. Por outro lado, a classe BB, que também apresenta relativa estabilidade entre os anos, porém com maior percentual de municípios (>26% em ambos os anos) está predominantemente evidenciado na região Norte, Nordeste e Centro-Oeste do Brasil. As categorias de transição (AB e BA) mantiveram-se com baixa frequência, refletindo a menor ocorrência de municípios outliers em relação ao padrão dos vizinhos.

Figura 13 - Distribuição espacial das emissões de CO₂ de origem fóssil nos municípios brasileiros




Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2004, ano de menor GISA e (b) 2016, ano de maior GISA.

A Figura 14 apresenta os resultados de LISA para o CO₂ de origem biogênica, representando os extremos temporais da série nesse caso. De forma análoga ao LISA de CO₂ fóssil (Figura 13), verifica-se predominância da classe NS em ambos os anos (>61%). A classe AA apresentou crescimento entre os anos analisados (de 5,6% para 6,3% dos municípios), com

novas concentrações espaciais no Sul, Sudeste e Centro-Oeste do Brasil. A classe BB manteve-se relativamente estável, com ampla dispersão territorial (~31%). As categorias de transição AB e BA permaneceram praticamente ausentes.


Figura 14 - Distribuição espacial das emissões de CO₂ de origem biogênica nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2000, ano de menor GISA e (b) 2023, ano de maior GISA.

Em relação ao CH₄, a análise da autocorrelação espacial local nos anos de menor (Figura 15a) e maior GISA (Figura 15b) revela estabilidade nos padrões espaciais observados. Em ambos os anos, $\geq 67\%$ dos municípios foram classificados como NS. Os agrupamentos de baixa emissão (BB) mantiveram proporção semelhante no período ($>27\%$), com ampla distribuição nas regiões Norte e Nordeste. Os agrupamentos de alta emissão (AA) mostraram ligeira oscilação percentual (0,1%). As categorias de transição (AB e BA) permaneceram pouco expressivas ($\leq 1,0\%$).


Figura 15 - Distribuição espacial das emissões de CH₄ nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2014, ano de menor GISA e (b) 2010, ano de maior GISA.

As emissões de N₂O evidenciam uma das distribuições espaciais mais definidas entre os gases analisados (Figura 16), com elevada concentração de municípios de classe AA, especialmente na região Sul, e menores municípios classificados como NS (>57%). A classe BB continua se evidenciando na região Norte e Nordeste (≥57% dos municípios). As classes de transição (AB e BA) apresentaram ocorrência residual (≤0,3%). A distribuição espacial relativamente constante, com destaque para a persistência dos *clusters* AA ao longo do período, sugere padrões territoriais consolidados de emissão de N₂O.


Figura 16 - Distribuição espacial das emissões de N₂O nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2014, ano de menor GISA e (b) 2022, ano de maior GISA.

A distribuição espacial das emissões agregadas de CO₂ equivalente revela um padrão consistente ao longo dos anos de menor (Figura 17a) e maior índice de GISA (Figura 17b). Observa-se predominância da classe NS (>64% dos municípios) em ambos os anos. Os agrupamentos BB apresentaram elevada estabilidade (30,0%), reforçando a presença de *clusters* de baixa intensidade espacialmente contínuos. Já os agrupamentos AA mantiveram proporção modesta, com ligeira redução de 5,2% para 4,9% entre 2014 e 2010. Assim como nos gases individuais, as classes de transição (AB e BA) foram mínimos ($\leq 0,4\%$), o que reforça a homogeneidade relativa do padrão espacial local no CO_{2eq}.

Figura 17 - Distribuição espacial das emissões de CO₂ equivalente (GWP-100) nos municípios brasileiros




Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2014, ano de menor GISA e (b) 2010, ano de maior GISA.

5.7.2 Indicadores socioeconômicos e demográficos

A espacialização do PIB per capita evidenciou padrões de autocorrelação local marcadamente estruturados nos anos de menor (Figura 18a) e maior (Figura 18b) GISA, com uma redução de municípios classificados como NS (-2,4%) entre os anos, indicando leve intensificação da autocorrelação local. Os agrupamentos de alta renda municipal (AA) aumentaram (+1,7%) com destaque para a ampliação espacial desses *clusters* em regiões do Centro-Oeste e Sul do Brasil. Paralelamente, os agrupamentos de baixa renda (BB) mantiveram relativa estabilidade (>29%), sobretudo concentrados nas porções Norte e Nordeste. As classes de transição (AB e BA) apresentaram baixa ocorrência ($\leq 2,1\%$ em ambos os anos), sugerindo padrões espaciais bem definidos e persistentes.


Figura 18 - Distribuição espacial do PIB per capita nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).
Legenda: (a) 2011, ano de menor GISA e (b) 2016, ano de maior GISA.

A análise de LISA da DD (Figura 19) revela um padrão relativamente estável ao longo do período, com predomínio marcante da classe NS (72,5% dos municípios em ambos os anos), indicando baixa autocorrelação local para a maior parte do território nacional. Os agrupamentos AA são menores (≤ 200 municípios), concentrando-se majoritariamente em capitais e regiões metropolitanas do Sudeste, Sul e Nordeste. Os agrupamentos BB mantiveram-se relativamente constantes ($>23,5\%$), sobretudo em áreas da região Norte e Centro-Oeste. As classes de transição (AB e BA) seguiram com baixa representatividade ($\leq 0,4\%$).


Figura 19 - Distribuição espacial da densidade demográfica nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).
Legenda: (a) 1999, ano de menor GISA e (b) 2022, ano de maior GISA.

A distribuição espacial do IU manteve padrões semelhantes ao observado para DD, com predomínio da classe NS em ambos os anos (>73%). Essa estabilidade reflete uma baixa autocorrelação local na maior parte do território, embora com indícios de intensificação da urbanização em regiões específicas com os agrupamentos AA, apresentaram leve aumento no período (de 4,1% para 4,6%), concentrando-se majoritariamente nas regiões Sul e Sudeste, especialmente em áreas costeiras e polos regionais consolidados. A classe BB também registrou crescimento (de 20,5% para 21,7%). As classes AB e BA permaneceram pouco representativas ($\leq 0,3\%$), indicando baixa incidência de descontinuidades espaciais significativas na distribuição do índice.

Figura 20 - Distribuição espacial do índice de urbanização nos municípios brasileiros



Fonte: Elaborado pelo autor (2024).

Legenda: (a) 1999, ano de menor GISA e (b) 2023, ano de maior GISA.

6 DISCUSSÃO

A análise realizada permitiu evidenciar a relevância dos fatores socioeconômicos e demográficos como condicionantes das emissões de CO_{2eq} nos municípios brasileiros, corroborando resultados obtidos em estudos internacionais e regionais (Alotaibi; Alajlan, 2021; Polloni-Silva *et al.*, 2021; Zheng *et al.*, 2016).

O vínculo positivo observado entre o IU e as emissões de CO_{2eq} indica que processos de urbanização intensos tendem a aumentar substancialmente a demanda energética, intensificando a exigência por infraestrutura urbana, transporte e habitação, o que resulta em maiores emissões de GEE. Tais resultados reforçam a importância do planejamento urbano integrado e sustentável, especialmente em regiões em rápido crescimento urbano, como apontado por Zheng *et al.* (2016) e Polloni-Silva *et al.* (2021).

Esse comportamento está fortemente associado à predominância de emissões de CO₂ de origem fóssil em contextos urbanos, vinculadas principalmente aos setores de transporte, geração de energia e atividades industriais (Zheng *et al.*, 2016; Alotaibi; Alajlan, 2021; Polloni-Silva *et al.*, 2021). A expansão urbana e a intensificação da infraestrutura energética elevam o consumo de combustíveis fósseis, reforçando padrões espaciais concentrados de emissões em áreas densamente urbanizadas e economicamente dinâmicas (Zheng *et al.*, 2016; Alotaibi; Alajlan, 2021; Polloni-Silva *et al.*, 2021).

Por outro lado, as emissões de CO₂ de origem biogênica apresentam dinâmica distinta, estando associadas, no contexto deste estudo, à combustão de biocombustíveis, como biomassa sólida e biocombustíveis líquidos, excluindo explicitamente as emissões provenientes de mudança de uso e cobertura da terra, queimadas em larga escala e processos associados ao setor de uso da terra, mudança de uso da terra e florestas, conforme a definição adotada no banco de dados EDGAR.

No contexto brasileiro, essas emissões tornam-se particularmente expressivas em setores vinculados ao uso energético da biomassa, refletindo fluxos de carbono decorrentes de processos de combustão em atividades industriais, energéticas e de transporte (Leite *et al.*, 2009; Sanquetta *et al.*, 2020; Gatti *et al.*, 2021). Essa diferenciação contribui para explicar padrões espaciais contrastantes entre o CO₂ fóssil e o CO₂ bio observados em análises territoriais.

De forma semelhante, a relação positiva identificada entre PIB *per capita* e emissões de CO_{2eq} indica que municípios economicamente mais desenvolvidos estão associados a maiores níveis de emissões, resultado consistente com o observado por Alotaibi e Alajlan (2021), ressaltando que padrões elevados de consumo e produção intensivos em carbono

acompanham o desenvolvimento econômico. Entretanto, destaca-se também a possibilidade de dissociação entre crescimento econômico e emissões mediante inovações tecnológicas, políticas ambientais eficazes e mudanças estruturais nas matrizes energéticas, conforme discutido por Husain *et al.* (2025) e IPCC (2023).

Por sua vez, é importante destacar que o PIB _{per capita}, embora amplamente utilizado como indicador do nível de desenvolvimento econômico, não captura diferenças regionais no custo de vida e no poder real de consumo (Costa *et al.*, 2022). Nesse sentido, indicadores baseados na paridade do poder de compra (PPC) podem oferecer uma leitura mais refinada das condições socioeconômicas, especialmente em países marcados por elevada heterogeneidade regional, como o Brasil (Moon *et al.*, 2010; World Bank, 2021; Šedivý; Janský, 2024).

Em relação à DD, a relação não significativa com o PIB _{per capita} indica que municípios densamente povoados nem sempre apresentam renda elevada. Tal constatação sugere uma importante diversidade estrutural nos municípios brasileiros, revelando complexidades regionais que exigem políticas públicas diferenciadas, capazes de considerar contextos socioeconômicos distintos e suas implicações para estratégias de mitigação das emissões de GEE (Mendes *et al.*, 2020).

As emissões de metano (CH₄) e óxido nitroso (N₂O) refletem ainda outras dinâmicas setoriais. No Brasil, o CH₄ está fortemente associado à pecuária, sobretudo à fermentação entérica, além do manejo de resíduos e atividades agroindustriais, o que explica sua distribuição espacial menos dependente de centros urbanos e de indicadores econômicos tradicionais (Chiquetto; Leichsenring; Santos, 2022; Pinto *et al.*, 2023). O N₂O, por sua vez, está majoritariamente relacionado ao uso de fertilizantes nitrogenados e a processos microbianos em solos agrícolas, apresentando emissões difusas e elevada variabilidade espacial, apesar de menores valores absolutos (Palermo *et al.*, 2014).

Em coerência com o estudo de Husain *et al.* (2025), que observaram que a densidade populacional nem sempre se traduz em maior eficiência energética ou desenvolvimento sustentável em países em desenvolvimento. Além disso, Arantes *et al.* (2021) evidenciam que a densidade populacional, em países com alta heterogeneidade regional, pode não ser um indicativo direto de desenvolvimento socioeconômico.

Adicionalmente, a análise temporal revelou a existência de forte dependência temporal nas variáveis municipais nos primeiros anos. Esse resultado indica que eventos passados e políticas públicas previamente implementadas exercem influência prolongada, embora decrescente ao longo do tempo, sobre os padrões de emissão atuais (Mendes *et al.*, 2020).

Esse comportamento reforça a relevância de considerar a dimensão temporal em estudos de emissões de GEE, destacando a necessidade de políticas ambientais que levem em conta os impactos cumulativos e duradouros das decisões anteriores sobre os níveis atuais e futuros de emissões (Polloni-Silva *et al.*, 2021; IPCC, 2023).

Outro aspecto relevante identificado neste estudo é a heterogeneidade temporal nas emissões municipais, com variações significativas ao longo do período analisado. Este fenômeno possivelmente reflete transformações estruturais ocorridas no país, relacionadas a alterações na composição econômica, mudanças regulatórias, adoção de tecnologias mais limpas e variações nas políticas públicas voltadas à gestão ambiental e energética, como sugerido em estudos de Polloni-Silva *et al.* (2021) e Zheng *et al.* (2016).

A utilização de modelos estatísticos que incorporam estruturas hierárquicas e efeitos aleatórios foi essencial para capturar adequadamente a variabilidade espacial e temporal das emissões nos municípios brasileiros. Essa abordagem permitiu avaliar como a variabilidade ao longo do tempo afeta o comportamento das emissões, revelando que as flutuações anuais e as tendências temporais exercem influência sobre os padrões observados (Gatti *et al.*, 2021; Alotaibi; Alajlan, 2021).

Complementarmente, os achados da análise de autocorrelação espacial global revelaram padrões espaciais persistentes nas emissões de GEE e nos indicadores socioeconômicos e demográfico ao longo do período. A alta significância estatística para todas as variáveis, associada à baixa variância dos índices anuais, corrobora a robustez estatística dos agrupamentos espaciais observados, indicando que a distribuição das emissões e seus fatores associados não é aleatória, refletindo dinâmicas territoriais estruturadas e persistentes (Ren *et al.*, 2019; Siljander *et al.*, 2022).

A análise local de autocorrelação espacial, por sua vez, aprofundou a compreensão sobre os contrastes regionais. A existência de áreas com agrupamentos sistemáticos de altas ou baixas emissões, acompanhadas por padrões socioeconômicos semelhantes entre municípios vizinhos, evidencia a necessidade de se considerar os efeitos de contiguidade espacial em estratégias de planejamento (Li *et al.*, 2023).

A persistência desses *clusters* ao longo do tempo, em especial nas regiões Norte, Nordeste e Centro-Oeste, onde exibiram baixas emissões e os menores valores dos índices socioeconômicos e demográficos, e Sudeste e Sul, com correlação oposta às demais regiões, sugere a reprodução de desigualdades ambientais e econômicas historicamente consolidadas (Martines *et al.*, 2021; Cima *et al.*, 2022).

Esse padrão territorial reproduz desigualdades regionais consolidadas no país, com assimetrias no processo de ocupação do território, na concentração de investimentos públicos e privados e na distribuição desigual da infraestrutura urbana e energética (Martines *et al.*, 2021; Cima *et al.*, 2022). A trajetória de desenvolvimento brasileiro historicamente favoreceu a concentração de recursos e serviços nos grandes centros urbanos do Sul e Sudeste, enquanto Norte e Nordeste mantiveram-se como regiões periféricas no modelo econômico nacional (Brito, 2006; Lobo, 2016; Marques; Saraiva, 2017).

7 CONCLUSÃO

O estudo permitiu concluir que as emissões municipais de GEE no Brasil apresentam significativa variabilidade espaço-temporal, fortemente associada às condições socioeconômicas e demográficas dos municípios. O PIB _{per capita} e o IU foram determinantes para explicar os padrões observados, indicando de que regiões mais urbanizadas e economicamente desenvolvidas apresentam maiores níveis de emissões.

Em contrapartida, a DD revelou relações menos consistentes com o padrão das emissões, sugerindo que o crescimento populacional, isoladamente, não implica diretamente em aumento proporcional das emissões.

A aplicação de métodos estatísticos adequados permitiu considerar explicitamente as estruturas temporais e hierárquicas presentes nos dados, evidenciando que as emissões não ocorrem de forma independente ao longo dos anos, mas possuem uma forte influência das condições passadas. A incorporação dessa perspectiva estatística mostrou-se essencial para obter resultados precisos e robustos.

A análise de autocorrelação espacial, por meio dos Índices de Moran, complementou a compreensão dos padrões territoriais, revelando a existência de agrupamentos persistentes e destacando desigualdades regionais historicamente consolidadas no Brasil. A identificação de agrupamentos espaciais associados aos níveis de desenvolvimento socioeconômico reforça a importância de se considerar as especificidades regionais na formulação de estratégias de mitigação.

Nesse sentido, as análises realizadas oferecem subsídios técnicos sólidos para políticas públicas voltadas à mitigação das emissões municipais, enfatizando a importância de considerar simultaneamente as especificidades socioeconômicas, demográficas e temporais no contexto brasileiro. Ao adotar a abordagem estatística multidimensional e fundamentada, este estudo contribui para o aprimoramento de estratégias ambientais alinhadas às metas globais de redução de emissões e aos compromissos internacionais associados ao ODS 13 (Ação Climática).

REFERÊNCIAS

- ABREU, N. L. *et al.* Land use change and greenhouse gas emissions: an explanation about the main emission drivers. **Ciência Animal Brasileira**, v. 25, p. 77646E, 2024.
- ADOM, P. K. The socioeconomic impact of climate change in developing countries over the next decades: A literature survey. **Heliyon**, v. 10, n. 15, 2024.
- AFZAL, A.; DIN, N. S.; HASAN, S. T. Climate Change and Socio-Economic Impacts: Determinants of Vulnerability for Developing Countries. **Journal of Peace, Development and Communication**, v. 8, n. 02, 2024.
- ALIBRANDI, A. *et al.* Hybrid professionals and academic productivity: the case of the university polyclinic in Messina (Sicily). **Health**, v. 13, n. 1, p. 1-15, 2021.
- ALOTAIBI, A. A.; ALAJLAN, N. Using quantile regression to analyze the relationship between socioeconomic indicators and carbon dioxide emissions in G20 countries. **Sustainability**, v. 13, n. 13, p. 7011, 2021.
- ALPINO, T. M. A. *et al.* Os impactos das mudanças climáticas na Segurança Alimentar e Nutricional: uma revisão da literatura. **Ciência & Saúde Coletiva**, v. 27, p. 273-286, 2022.
- ANSELIN, L.; SYABRI, I.; KHO, Y. GeoDa: an introduction to spatial data analysis. *In: Handbook of applied spatial analysis: Software tools, methods and applications*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2009. p. 73-89.
- ARANTES, B. L. *et al.* Urban forest and per capita income in the mega-city of Sao Paulo, Brazil: A spatial pattern analysis. **Cities**, v. 111, p. 103099, 2021.
- BARCELLOS, C. *et al.* Climate change and health challenges on the world's periphery. **Cien Saude Colet**, 2025.
- BEALE, C. M. *et al.* Regression analysis of spatial data. *Ecology letters*, v. 13, n. 2, p. 246-264, 2010.
- BEZYK, Y. *et al.* GIS-based approach to spatio-temporal interpolation of atmospheric CO2 concentrations in limited monitoring dataset. **Atmosphere**, v. 12, n. 3, p. 384, 2021.
- BHUSAL, U. P.; SAPKOTA, V. P. Socioeconomic and demographic correlates of child nutritional status in Nepal: an investigation of heterogeneous effects using quantile regression. **Globalization and Health**, v. 18, n. 1, p. 42, 2022.
- BOX, G. E. P. *et al.* **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2015.
- BRASIL. MCTI, Ministério da Ciência, Tecnologia e Inovação. **Caderno de sínteses técnico-científicas sobre impactos, vulnerabilidade e adaptação no Brasil para o Plano Clima Adaptação**. Brasília: MCTI, 2025. Disponível em: <https://www.undp.org/pt/brazil/publications/caderno-de-sinteses-tecnico-cientificas-sobre->

impactos-vulnerabilidades-e-adaptacao-no-brasil-para-o-plano-clima-adaptacao. Acesso em: 28 set 2025.

BRITO, F. O deslocamento da população brasileira para as metrópoles. **Estudos avançados**, v. 20, p. 221-236, 2006.

BTCast ABC2: Ciência e religião. [Locução de]: Rodrigo Bibó. 2022. Podcast. Disponível em: <https://bibotalk.com/podcast/ciencia-e-religiao-btcast-abc2-040/>. Acesso em: 26 out. 2024.

BURMESTER, A. B. *et al.* Marketing inputs and outcome heterogeneity: Using a quantile regression framework in the entertainment industry. **Journal of the Academy of Marketing Science**, v. 53, n. 1, p. 232-254, 2025.

CANADELL, J. G. *et al.* Global Carbon and other Biogeochemical Cycles and Feedbacks. In: MASSON-DELMOTTE, V. *et al.* **Climate Change 2021: The Physical Science Basis**. Cambridge, United Kingdom and New York: Cambridge University Press, 2021. cap. 5, p. 673–816.

CAPELARI, M. G. M. *et al.* Large-scale environmental policy change: analysis of the Brazilian reality. **Revista de Administração Pública**, v. 54, n. 6, p. 1691-1710, 2020.
CHEN, Y. An analytical process of spatial autocorrelation functions based on Moran's index. **PLoS One**, v. 16, n. 4, p. e0249589, 2021.

CHIMELI, A. B.; GUILHOTO, J. J. M.; GATTI, L. Socio-economic drivers of greenhouse gas emissions in the Brazilian Amazon: new evidence from Santarém, Pará. **Munich Personal RePEc Archive**, 2011.

CHIQUELLO, J. B.; LEICHSENRING, A. R.; SANTOS, G. M. Socioeconomic conditions and fossil fuel CO₂ in the Metropolitan Area of Rio de Janeiro. **Urban Climate**, v. 43, p. 101176, 2022.

CIMA, E. G. *et al.* Spatial analysis: a socioeconomic view on the incidence of the new coronavirus in Paraná-Brazil. **Stats**, v. 5, n. 4, p. 1029-1043, 2022.

COSTA, A. *et al.* The impact of estimated sub-national purchasing power parity on macroeconomic measures. **Statistical Journal of the IAOS**, v. 38, n. 4, p. 1349-1365, 2022.

CRIBARI-NETO, F.; SILVA, W. B. A new heteroskedasticity-consistent covariance matrix estimator for the linear regression model. **ASTA Advances in Statistical Analysis**, v. 95, p. 129-146, 2011.

CRIPPA, M. *et al.* Insights into the spatial distribution of global, national, and subnational greenhouse gas emissions in the Emissions Database for Global Atmospheric Research (EDGAR v8.0). **Earth System Science Data**, v. 16, n. 6, p. 2811-2830, 2024.

DABUO, F. T. *et al.* Influence of research and development, environmental regulation, and consumption of energy on CO₂ emissions in China—novel spatial Durbin model perspective. **Environmental Science and Pollution Research**, v. 30, n. 11, p. 29065-29085, 2023.

DOBSON, A.J.; BARNETT, A. G. **An introduction to generalized linear models**. New York: Chapman and Hall/CRC, 2018.

DUTRA, D. J. *et al.* Challenges for reducing carbon emissions from land-use and land cover change in Brazil. **Perspectives in Ecology and Conservation**, v. 22, n. 3, p. 213-218, 2024.

DUTSE, A. I. Nexus between Climate Change, Conflict and Human Security in Nigeria. **Nnamdi Azikiwe Journal of Political Science**, v. 9, n. 1, p. 40-53, 2024.

EHHALT, D. *et al.* Atmospheric Chemistry and Greenhouse Gases. *In: Climate Change 2001: The Scientific Basis*. Cambridge, United Kingdom and New York: Cambridge University Press, 2001. cap. 4, p. 239-287.

ESRI, Environmental Systems Research Institute. **ArcGIS Desktop: Release 10.8** [software]. Redlands: Esri, 2020.

ETMINAN, M. *et al.* Radiative forcing of carbon dioxide, methane, and nitrous oxide: A significant revision of the methane radiative forcing. **Geophysical Research Letters**, v. 43, n. 24, p. 12,614-12,623, 2016.

FONTOURA, C. F. M.; PUGLIESI, E. A.; TACHIBANA, V. M. The influence of slope on the identification of urban centralities: a case study in the municipality of Barra do Piraí, State of Rio de Janeiro, Brazil. **Boletim de Ciências Geodésicas**, v. 29, n. 4, p. e2023009, 2023.

FORSTER, P. T. *et al.* The Earth's Energy Budget, Climate Feedbacks, and Climate Sensitivity. *In: Climate Change 2021: The Physical Science Basis*. Contribution of Working Group I to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, United Kingdom e New York: Cambridge University Press, 2021. p. 923-1054.

FRIEDLINGSTEIN, P. *et al.* Global Carbon Budget 2022. **Earth System Science Data**, v. 14, n. 11, p. 4811-4900, 2022.

GATTI, L. V. *et al.* Amazonia as a carbon source linked to deforestation and climate change. **Nature**, v. 595, n. 7867, p. 388-393, 2021.

GHASEMI, A.; ZAHEDIASL, S. Normality tests for statistical analysis: a guide for non-statisticians. **International journal of endocrinology and metabolism**, v. 10, n. 2, p. 486, 2012.

GIBBONS, J. D.; CHAKRABORTI, S. **Nonparametric statistical inference: revised and expanded**. Boca Raton: CRC press, 2014.

GONZÁLEZ-SÁNCHEZ, M.; MARTÍN-ORTEGA, J. L. Greenhouse gas emissions growth in Europe: a comparative analysis of determinants. **Sustainability**, v. 12, n. 3, p. 1012, 2020.

GUJARATI, D. N.; PORTER, D. C. **Basic econometrics**. 5th ed. New York: McGraw-Hill, 2009.

GUO, R. *et al.* Impact of urban form on CO₂ emissions under different socioeconomic factors: evidence from 132 small and medium-sized cities in China. **Land**, v. 11, n. 5, p. 713, 2022.

HUSAIN, S. A. *et al.* Financial Development and Population Growth as Drivers of Environmental Change: Evidence from South Asia. **Indus Journal of Social Sciences**, v. 3, n. 1, p. 526-536, 2025.

IBGE, Instituto Brasileiro de Geografia e Estatística. Censo Demográfico 2022. IBGE, 2025. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/saude/22827-censo-demografico-2022.html>. Acesso em: 28 set 2025.

IBGE, Instituto Brasileiro de Geografia e Estatística. Metodologia das estimativas das populações municipais: 2011. Rio de Janeiro: IBGE, 2013. 80 p. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv101696.pdf>. Acesso em: 08 ago. 2024.

IPCC, Intergovernmental Panel on Climate Change. **Climate Change 2021: The Physical Science Basis**. Cambridge, United Kingdom e New York: Cambridge University Press, 2021. p. 2391.

IPCC, Intergovernmental Panel on Climate Change. **Global Warming of 1.5°C: An IPCC Special Report on the impacts of global warming of 1.5°C above pre-industrial levels and related global greenhouse gas emission pathways, in the context of strengthening the global response to the threat of climate change, sustainable development, and efforts to eradicate poverty**. Cambridge, United Kingdom e New York: Cambridge University Press, 2018. p. 616.

IPCC, Intergovernmental Panel on Climate Change. Sections. *In*: IPCC. **Climate Change 2023: Synthesis Report. Contribution of Working Groups I, II and III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change**. Geneva, Switzerland: IPCC, 2023. p. 35-115.

JONES, C.; KAMMEN, D. M. Spatial distribution of US household carbon footprints reveals suburbanization undermines greenhouse gas benefits of urban population density. **Environmental science & technology**, v. 48, n. 2, p. 895-902, 2014.

JONES, M. W. *et al.* National contributions to climate change due to historical emissions of carbon dioxide, methane, and nitrous oxide since 1850. **Scientific Data**, v. 10, n. 1, p. 155, 2023.

KIM, J. H. Multicollinearity and misleading statistical results. **Korean journal of anesthesiology**, v. 72, n. 6, p. 558-569, 2019.

KO, I.; LEE, T. Carbon pricing and decoupling between greenhouse gas emissions and economic growth: A panel study of 29 European countries, 1996–2014. **Review of Policy Research**, v. 39, n. 5, p. 654-673, 2022.

LEITE, C. C. *et al.* Historical land use change and associated carbon emissions in Brazil from 1940 to 1995. **Global Biogeochemical Cycles**, v. 26, n. 2, 2012.

- LI, A. *et al.* The impact of urbanization on carbon emissions and spatial–temporal differentiation based on meta-analysis in China. **Sustainability**, v. 14, n. 22, p. 14840, 2022.
- LI, L. *et al.* Enhanced nitrous oxide emission factors due to climate change increase the mitigation challenge in the agricultural sector. **Global change biology**, v. 30, n. 8, p. e17472, 2024.
- LI, Y. *et al.* Change of Human Footprint in China and Its Implications for Carbon Dioxide (CO₂) Emissions. **Remote Sensing**, v. 15, n. 2, p. 426, 2023.
- LI, Z.; WU, H.; WU, F. Impacts of urban forms and socioeconomic factors on CO₂ emissions: A spatial econometric analysis. **Journal of Cleaner Production**, v. 372, p. 133722, 2022.
- LIU, K. *et al.* Spatio-temporal analysis of population-land-economic urbanization and its impact on urban carbon emissions in Shandong Province, China. **Land**, v. 11, n. 2, p. 266, 2022.
- LOBO, C. Dispersão espacial da população no Brasil. **Mercator**, v. 15, n. 3, p. 19-36, 2016.
- LUZARDO, A. J. R.; CASTAÑEDA FILHO, R. M.; RUBIM, I. B. Análise espacial exploratória com o emprego do índice de Moran. **GEOgraphia**, v. 19, n. 40, p. 161-179, 2017.
- MAR, K. A. *et al.* Beyond CO₂ equivalence: The impacts of methane on climate, ecosystems, and health. **Environmental science & policy**, v. 134, p. 127-136, 2022.
- MARQUES, E.; SARAIVA, C. Urban integration or reconfigured inequalities? Analyzing housing precarity in São Paulo, Brazil. **Habitat International**, v. 69, p. 18-26, 2017.
- MARTINES, M. R. *et al.* Detecting space–time clusters of COVID-19 in Brazil: mortality, inequality, socioeconomic vulnerability, and the relative risk of the disease in Brazilian municipalities. **Journal of Geographical Systems**, v. 23, n. 1, p. 7-36, 2021.
- MCKIGHT, P. E.; NAJAB, J. Kruskal-wallis test. **The corsini encyclopedia of psychology**, p. 1-1, 2010.
- MENDES, W. A. *et al.* Desenvolvimento humano e desigualdades regionais nos municípios brasileiros. **Latin American Research Review**, v. 55, n. 4, p. 742-758, 2020.
- MOON, S.; PAGE, S.; RODIN, B.; ROY, D. **Purchasing power parity measures: advantages and limitations**. London: Overseas Development Institute, 2010. Disponível em: <https://media.odi.org/documents/6018.pdf>. Acesso em: 7 dez 2025.
- MUTTARAK, R. Demographic perspectives in research on global environmental change. **Population Studies**, v. 75, n. sup1, p. 77-104, 2021.
- NELDER, J. A.; WEDDERBURN, R. W. M. Generalized linear models. **Journal of the Royal Statistical Society Series A: Statistics in Society**, v. 135, n. 3, p. 370-384, 1972.

NOAA, National Oceanic and Atmospheric Administration. **Annual Greenhouse Gas Index (AGGI)**. Global Monitoring Laboratory, 2025. Disponível em: <https://gml.noaa.gov/aggi/aggi.html>. Acesso em: 26 set 2025.

OBERGASSEL, W. *et al.* The potential of international institutions to foster transitions. The example of the Global Stocktake under the Paris Agreement. **Environmental Innovation and Societal Transitions**, v. 57, p. 101005, 2025.

OLSSON, L. *et al.* Land Degradation. In: IPCC. **Climate Change and Land: an IPCC special report on climate change, desertification, land degradation, sustainable land management, food security, and greenhouse gas fluxes in terrestrial ecosystems**. Cambridge, United Kingdom e New York: Cambridge University Press, 2019. p. 345-436.

PALERMO, G. C. *et al.* Reduction of emissions from Brazilian cattle raising and the generation of energy: Intensification and confinement potentials. **Energy Policy**, v. 68, p. 28-38, 2014.

PINTO, T. P.; LIMA, C. Z.; ESTEVAM, C. G.; PAVÃO, E. M.; ASSAD, E. D. **Overview of Methane Emissions and implications of different metrics**. São Paulo: Fundação Getulio Vargas, 2023. Disponível em: https://agro.fgv.br/sites/default/files/2023-02/eesp_relatorio_metano-eng_ap1_v1.pdf. Acesso em: 7 dez 2025.

POLLONI-SILVA, E. *et al.* The drivers of energy-related CO₂ emissions in Brazil: A regional application of the STIRPAT model. **Environmental Science and Pollution Research**, v. 28, n. 37, p. 51745-51762, 2021.

Posit Team. **RStudio**: Integrated Development Environment for R [software]. Posit Software, PBC. 2023.

R Core Team. **R**: A language and environment for statistical computing [software]. Vienna, Austria: R Foundation for Statistical Computing, 2024.

RAIHAN, A. The interrelationship amid carbon emissions, tourism, economy, and energy use in Brazil. **Carbon Research**, v. 3, n. 1, p. 11, 2024.

RAJÃO, R. *et al.* The risk of fake controversies for Brazilian environmental policies. **Biological conservation**, v. 266, p. 109447, 2022.

REN, Z. *et al.* Changes in spatio-temporal patterns of urban forest and its above-ground carbon storage: Implication for urban CO₂ emissions mitigation under China's rapid urban expansion and greening. **Environment International**, v. 129, p. 438-450, 2019.

RIAHI, K. R. *et al.* Mitigation pathways compatible with long-term goals. In: IPCC. **Climate Change 2022: Mitigation of Climate Change**. Contribution of Working Group III to the Sixth Assessment Report of the Intergovernmental Panel on Climate Change. Cambridge, United Kingdom e New York: Cambridge University Press, 2022. p. 295-408.

SANGUINET, E. R. Regional inequality and CO₂ emissions-based trade across value chains networks: a multiscalar analysis from Brazilian states. **Regional Studies, Regional Science**, v. 9, n. 1, p. 135-148, 2022.

SANQUETTA, C. *et al.* Greenhouse gas emissions due to land use change in Brazil from 1990 to 2015: comparison of methodological approaches. **Desenvolvimento e Meio Ambiente**, 2020.

SANTOS-DEGNER, L. A. *et al.* Mudanças climáticas, insegurança alimentar e seus impactos na saúde e nutrição infantil no Brasil: proposta de modelo conceitual. **Cadernos de Saúde Pública**, v. 41, p. e00217824, 2025.

ŠEDIVÝ, M.; JANSKÝ, P. How do regional price levels affect income inequality? Household-level evidence from countries worldwide. **The Annals of Regional Science**, v. 74, n. 1, p. 1-63, 2025.

SHUKLA, K. *et al.* Mapping spatial distribution of particulate matter using Kriging and Inverse Distance Weighting at supersites of megacity Delhi. **Sustainable cities and society**, v. 54, p. 101997, 2020.

SILJANDER, M. *et al.* Spatiotemporal clustering patterns and sociodemographic determinants of COVID-19 (SARS-CoV-2) infections in Helsinki, Finland. **Spatial and spatio-temporal epidemiology**, v. 41, p. 100493, 2022.

SILVA, D. C. C. *et al.* Análise da relação entre a distribuição espacial das morbidades por obesidade e hipertensão arterial para o estado de São Paulo, Brasil, de 2000 a 2010. **Ciência & Saúde Coletiva**, v. 19, p. 1709-1719, 2014.

SILVA, D. C. C. *et al.* Spatial autocorrelation proposal of the relationship between the socioeconomic conditions in Metropolitan Region of Sorocaba, SP, Brazil. **Ciência e Natura**, v. 43, p. 42, 2021.

SOUSA-NETO, E. R. *et al.* Land use and land cover transition in Brazil and their effects on greenhouse gas emissions. In: **Soil management and climate change**. Academic Press, 2018. p. 309-321.

SPC, Pacific Community. **Natural disasters and climate change survey module**: sourcebook. Noumea, New Caledonia: Pacific Community, 2023. Disponível em: <https://www.spc.int/resource-centre/publications/climate-change-and-natural-disasters-sourcebook>. Acesso em: 28 set 2025.

SUFYANULLAH, K.; AHMAD, K. A.; ALI, M. A. S. Does emission of carbon dioxide is impacted by urbanization? An empirical study of urbanization, energy consumption, economic growth and carbon emissions-Using ARDL bound testing approach. **Energy Policy**, v. 164, p. 112908, 2022.

SUMUNAR, D. R. S.; ARIF, N.; KHOTIMAH, N. Identification of Spatial Clusters of COVID-19 in Yogyakarta using Moran's Index. In: **IOP Conference Series: Earth and Environmental Science**. IOP Publishing, 2021. p. 012058.

UNDESA, The United Nations Department of Economic and Social Affairs (2025). **Goal 13**: Take urgent action to combat climate change and its impacts. Sustainable Development Goals. Disponível em: <https://sdgs.un.org/goals/goal13>. Acesso em: 04 fev. 2025.

UNFCCC, United Nations Framework Convention on Climate Change. **Paris Agreement**. Report of the Conference of the Parties to the UNFCCC on its twenty-first session, held in Paris from 30 November to 13 December 2015. 2015 Disponível em: https://unfccc.int/sites/default/files/english_paris_agreement.pdf. Acesso em: 04 fev. 2025.

UN, United Nations. **Transforming our world: the 2030 Agenda for Sustainable Development**. Resolution adopted by the General Assembly on 25 September 2015. United Nations General Assembly, 2015. Disponível em: <https://sdgs.un.org/2030agenda>. Acesso em: 04 fev. 2025.

VAN DER BORGH, R.; BARBERA, M. P. How urban spatial expansion influences CO₂ emissions in Latin American countries. **Cities**, v. 139, p. 104389, 2023.

WANG, B. *et al.* Spatio-temporal patterns of CO₂ emissions and influencing factors in China using ESDA and PLS-SEM. **Mathematics**, v. 9, n. 21, p. 2711, 2021.

WORLD BANK. **Purchasing Power Parities for Policy Making: A Visual Guide to Using Data from the International Comparison Program**. Washington, DC: World Bank, 2021. Disponível em: <https://documents1.worldbank.org/curated/en/779381623349931051/pdf/Purchasing-Power-Parities-for-Policy-Making-A-Visual-Guide-to-Using-Data-from-the-International-Comparison-Program.pdf>. Acesso em: 7 dez 2025.

YANG, Y. *et al.* Urban density and spatial carbon emission performance of megacities in China. **Scientific Reports**, v. 14, n. 1, p. 23862, 2024.

YOUNG, A. F. Urbanization, environmental justice, and social-environmental vulnerability in Brazil. **Urbanization and Sustainability: Linking Urban Ecology, Environmental Justice and Global Environmental Change**, p. 95-116, 2013.

ZHENG, H. *et al.* Examining determinants of CO₂ emissions in 73 cities in China. **Sustainability**, v. 8, n. 12, p. 1296, 2016.

ZHU, E.; QI, Q.; CHEN, L.; WU, X. The spatial-temporal patterns and multiple driving mechanisms of carbon emissions in the process of urbanization: a case study in Zhejiang, China. **Journal of Cleaner Production**, v. 358, p. 131954, 2022.