

MODELAGEM ESPACIAL DOS FATORES ASSOCIADOS À ANTROPIZAÇÃO NA MATA ATLÂNTICA BAIANA

Spatial modelling of factors associated with anthropisation in the Bahian Atlantic Forest

Paula Fabyanne Marques Ferreira

Professora Mestra em Geografia, Doutoranda pela Universidade Federal do Sul da Bahia, Itabuna, Bahia, Brasil

paula.marques@gfe.ufsb.edu.br

Ariana Sales Batista

Advogada, Mestranda pela Universidade Federal do Sul da Bahia, Itabuna, Bahia, Brasil

ariana.batista@gfe.ufsb.edu.br

Alex Mota dos Santos

Professor Doutor em Geografia, Universidade Federal do Sul da Bahia, Itabuna, Bahia, Brasil

alex.geotecnologias@gmail.com

Gerson dos Santos Lisboa

Engenheiro Florestal, Professor Doutor, Universidade Federal de Goiás, Brasil.

gersonlisboa@ufg.br

Luanna Chácara Pires

Professora Doutora, Universidade Federal do Sul da Bahia, Teixeira de Freitas, Bahia, Brasil

luanna.pires@gfe.ufsb.edu.br

Rafael Henrique de Freitas Noronha

Professor Doutor, Universidade Federal do Sul da Bahia, Itabuna, Bahia, Brasil

rafael.noronha@ufsb.edu.br

Recebido: 30/07/2025

Aceito: 16/03/2026

Resumo

A Mata Atlântica é um dos biomas mais ameaçados do Brasil, devido à pressão antrópica intensa e prolongada. Essa dinâmica de transformação é significativa no estado da Bahia, onde tais processos se manifestam de forma histórica e contínua. Este estudo teve como objetivo identificar e modelar espacialmente os principais fatores associados à área antropizada nos municípios baianos do bioma. A etapa inicial consiste na análise exploratória dos dados, verificando-se a distribuição, a dispersão e as possíveis relações entre as variáveis. Utilizou-se um modelo de regressão de Mínimos Quadrados Ordinários (MQO) como linha de base, seguido de uma análise de Regressão Geograficamente Ponderada (RGP), na qual se verificou a ausência de estacionariedade espacial dos fenômenos. A variável dependente foi identificada como a área antropizada, e as variáveis explicativas incluíram fatores de produção agrícola, agropecuária, demográficos, de infraestrutura e ambientais. Foi identificado que o valor de R^2 (Coeficiente de Determinação) ajustado do MQO é de 0,38, já o do RGP é de 0,60, o que indica que o RGP explicou 60% das variações na área antropizada. Ademais, ficou evidente que os impulsionadores da antropização, como a área agropecuária e a malha viária, variam significativamente em

intensidade ao longo do território baiano. O resultado é consistente, considerando a composição heterogênea da área de estudo, com dinâmicas socioeconômicas, ambientais e territoriais distintas.

Palavras-chave: Preditores; desmatamento; análise em biosistemas; geoprocessamento.

Abstract

The Atlantic Forest is one of the most threatened biomes in Brazil due to intense and prolonged anthropogenic pressure. This dynamic of transformation is significant in the state of Bahia, where such processes manifest themselves historically and continuously. This study aimed to identify and spatially model the main factors associated with the anthropized area in the municipalities of Bahia located within the biome. The initial stage consisted of an exploratory data analysis, verifying the distribution, dispersion, and possible relationships between the variables. An Ordinary Least Squares (OLS) regression model was used as a baseline, followed by a Geographically Weighted Regression (GWR) analysis, which verified the spatial non-stationarity of the phenomena. The dependent variable was identified as the anthropized area, and the explanatory variables included agricultural production, livestock, demographic, infrastructure, and environmental factors. It was identified that the adjusted R^2 (Coefficient of Determination) value for OLS is 0.38, while that for GWR was 0.60, meaning that GWR explained 60% of the variations in the anthropized area. Furthermore, it became evident that the drivers of anthropization, such as agricultural areas and the road network, vary significantly in their intensity across the territory of Bahia. The result is consistent, considering the heterogeneous composition of the study area, with different socioeconomic, environmental, and territorial dynamics.

Keywords: Predictors; deforestation; biosystem analysis; geoprocessing.

1. INTRODUÇÃO

A Mata Atlântica é o bioma de ocupação mais antiga no Brasil, um dos mais degradados do país, com processos de antropização desde a colonização no século XVI. A longa história de ocupação humana ao longo dos séculos resultou em vulnerabilidades, devido a ameaças com efeitos regionais (como mudanças contínuas no uso da terra, caça) ou global (mudança climática, invasão biológica) (Grelle; Rajão e Marques, 2021; Costa *et al.*, 2024). Com a implementação do empreendimento colonial português, em menos de 500 anos, grande parte da Mata Atlântica foi transformada em uma matriz não florestal (Solórzano; Brasil; Oliveira, 2021).

A dinâmica antrópica em prol do crescimento econômico e por conseguinte, a modificação no uso da terra e os decorrentes impactos socioambientais, já são uma realidade conhecida e significativamente investigada em estudos geográficos envolvendo a fragmentação desse importante bioma (Guimarães *et al.*, 2023). Mesmo assim, é fundamental reconhecer que os remanescentes da Mata Atlântica no Brasil são significativos para a biodiversidade e proporcionam benefícios para as pessoas

(regulamentação climática, abastecimento de água, saúde e bem-estar, entre outros) (Coelho-Junior, 2021).

Para Grelle, Rajão e Marques (2021), mesmo nesse cenário desfavorável, surgem oportunidades que são capazes de conciliar a conservação da biodiversidade e dos serviços ecossistêmicos com o desenvolvimento social e econômico do Brasil. Nesse sentido, pesquisas foram apresentadas e que contribuem para compor o cenário de degradação da Mata Atlântica e os seus motivadores. Guimarães *et al.* (2023) analisaram os fatores condicionantes do desmatamento do Bioma Mata Atlântica/Brasil, entre 2010 e 2020 e constataram que o desmatamento está relacionado à vulnerabilidade socioeconômica e à baixa governança ambiental. Observaram ainda que a pecuária é a principal atividade que impacta a estabilidade dos recursos naturais.

Nesse contexto, ainda segundo Guimarães *et al.* (2023), o padrão de desmatamento da Mata Atlântica não é uniforme, pois há diferentes estágios de exploração da vegetação. Varia nos grandes centros urbanos (como as regiões metropolitanas de São Paulo e Rio de Janeiro) até áreas rurais, com destaque para as regiões Nordeste e Sudeste (Guimarães *et al.*, 2023). A urbanização é acelerada no Brasil, isto é especialmente verdadeiro em cidades da costa leste, em áreas de Mata Atlântica, onde mais de 70% da população está concentrada (Freitas *et al.*, 2020).

A situação é especialmente crítica no Estado da Bahia, onde o histórico processo de ocupação, aliado à expansão urbana, marcada pela intensificação da especulação imobiliária e das atividades agropecuárias, têm contribuído de forma significativa para a antropização das paisagens. Neste estudo, a antropização é compreendida como o conjunto de transformações provocadas pela ação humana sobre o meio natural, resultando na substituição da vegetação nativa por diferentes formas de uso antrópico, como agricultura, pecuária, urbanização, implantação de infraestrutura e exploração de recursos naturais (Silva *et al.*, 2018). Em escala global é aceito que aproximadamente 70% da superfície da Terra já sofreu algum tipo de alteração antropogênica, convertendo florestas nativas para produção agrícola, infraestrutura e uso urbano (Silveira *et al.*, 2022).

A análise geográfica da antropização pode ser realizada de diversas formas, dentre as quais através da modelagem espacial dos fatores que condicionam tal fenômeno. A modelagem estatística aplicada a análise geográfica auxilia na compreensão dos processos que levam à perda de cobertura vegetal, distinguindo correlações causais mais robustas. Estudos recentes vêm corroborando que bases de dados estatísticos contribuem nas tomadas de decisão visando para priorizar áreas para conservação, restaurar corredores

ecológicos e orientar práticas de uso do solo mais sustentáveis (Santos *et al.*, 2021; Oliveira *et al.*, 2022; Guimarães *et al.*, 2023). Além disso, se constitui como ferramenta significativa para análise e interpretação dos padrões, possibilitando a identificação de áreas críticas e correlações com variáveis socioeconômicas e ambientais.

Assim, este estudo tem como objetivo identificar os principais fatores associados à antropização nos municípios total ou parcialmente inseridos no Bioma Mata Atlântica, no Estado da Bahia. Além disso, busca contribuir de maneira abrangente para o debate em torno dos Objetivos de Desenvolvimento Sustentável (ODS). A análise se alinha diretamente ao ODS 15 (Vida Terrestre), ao investigar os vetores de pressão sobre ecossistemas e a biodiversidade. De forma indireta, também fornece subsídios para o ODS 11 (Cidades e Comunidades Sustentáveis), ao modelar os impactos de fatores demográficos e de infraestrutura sobre o uso do solo; para o ODS 12 (Consumo e Produção Responsáveis), ao examinar os padrões da agropecuária; e para o ODS 13 (Ação Contra a Mudança Global do Clima), considerando que o desmatamento figura entre os principais responsáveis pelas emissões de gases de efeito estufa.

2. MATERIAL E MÉTODOS

Para atender ao objetivo proposto, adotou-se uma abordagem quantitativa baseada em análise espacial e modelagem estatística. Os procedimentos metodológicos envolveram a organização e o tratamento de dados secundários de natureza ambiental, socioeconômica, demográfica, agropecuária e de infraestrutura, seguidos por análise exploratória, verificação de relações entre variáveis e aplicação de modelos de regressão. Inicialmente, utilizou-se a Regressão por Mínimos Quadrados Ordinários (MQO), como modelo global de referência e, posteriormente, aplicou-se a Regressão Geograficamente Ponderada (RGP), com o intuito de investigar a existência de não estacionariedade espacial nos fatores associados à área antropizada nos municípios baianos inseridos no bioma Mata Atlântica. Na sequência, são apresentados a área de estudo e o detalhamento dos procedimentos metodológicos adotados.

2.1. Área de Estudo

A área de estudo compõe-se dos 194 municípios, localizados no Estado da Bahia, que estão inseridos no Bioma Mata Atlântica (Figura 1). Esses municípios representam aproximadamente 35% da área total do Estado da Bahia, cuja extensão territorial é de cerca

de 564.733 km² (IBGE, 2023). De modo geral, segundo os dados e informações do Projeto MapBiomas 67% de toda a área da Mata Atlântica é ocupada por uso antrópico. Ademais, a agricultura cresceu 91% em relação a área ocupada desde 1985 (MapBiomas, 2024). Ainda segundo o MapBiomas (2024), nas áreas naturais, a floresta (formação florestal, mangue e restinga) foi o tipo de cobertura que mais perdeu área em 39 anos (1985-2024).




Figura 1 - Localização da área de estudo.

Fonte: Elaboração própria, 2025.

A Mata Atlântica, um dos biomas mais biodiversos do mundo (Marques *et al.*, 2021), é um dos principais biomas brasileiros, de natureza tropical úmida, apresentando elevada biodiversidade e heterogeneidade ecológica (Romanelli *et al.*, 2022). Estende-se ao longo da costa atlântica brasileira, limitando-se, no Nordeste, com o Bioma Caatinga; no Sudeste, com o Bioma Cerrado; e, na Região Sul, com a Floresta Ombrófila Mista — esta última caracterizada pela presença de *Araucaria angustifolia*, espécie símbolo das florestas subtropicais brasileiras (Scarano, 2014).

Na Bahia, a Mata Atlântica compõe uma paisagem marcada pela heterogeneidade, reunindo diferentes formas de uso do solo e fragmentos florestais de variados tamanhos

(Guimarães *et al.*, 2023). Essa variabilidade reflete os distintos padrões de uso e ocupação do solo, influenciados pelas atividades socioeconômicas predominantes em cada região do estado (Sampaio *et al.* 2024).

2.2. Procedimentos metodológicos

A metodologia adotada neste estudo está dividida em três etapas: (1) Aquisição de dados; (2) Processamento e organização das informações; e (3) Análise estatística e espacial, sintetizada no fluxograma da Figura 2.




Figura 2 - Fluxograma da Metodologia.

Fonte: Elaboração própria, 2025.

2.2.1. Aquisição dos Dados e informações

Foram coletados dados referentes aos anos de 2020 a 2023 e agrupados conforme a natureza das variáveis, disponíveis na Tabela 1. As variáveis dependentes foram extraídas da Coleção 9.0 do Projeto MapBiomias (Souza *et al.*, 2020), que utiliza imagens do Land Remote Sensing Satellite (LANDSAT), para classificar e monitorar o uso e cobertura da terra com uma resolução espacial de 30 metros (pixels de 30x30 metros). A

escolha desta base fundamenta-se em sua robusta amplitude temporal e homogeneidade metodológica, atributos que viabilizam a caracterização longitudinal dos processos de antropização sob um panorama evolutivo consistente. Ademais, a aplicação de mapeamentos com resoluções espaciais mais refinadas (como Sentinel-2 de 10 metros ou dados sub-métricos, por exemplo) para áreas de grande extensão biômica imporia desafios operacionais e custos computacionais significativos relacionados ao processamento de grandes volumes de dados (Big Data), o que comprometeria a viabilidade do estudo. Nesse sentido, a utilização dos dados do MapBiomas assegura a reprodutibilidade da análise e a exequibilidade da pesquisa em escalas macrogeográficas.

Tabela 1: Descrição e fonte das variáveis utilizadas no estudo

Categoria	Variáveis explicativas	Abreviações	Fonte
Agricultura	Área da Produção Agrícola Municipal	POD_AGRI	SIDRA / IBGE (2020-2023)
Agricultura	Área Plantada de Cacau	CACAU	SIDRA / IBGE (2020-2023)
Agropecuária	Número de Bovinos	MED_BOV	SIDRA / IBGE (2020-2023)
Demografia	Número de Habitantes (estimativas dos anos de 2020 e 2021)	MED_POP	SIDRA / IBGE (2020-2022)
Infraestrutura	Malha Viária	KM_ROD	DNIT
Conservação	Área de Unidades de Conservação de Uso Sustentável	UC_SUST	ICMBio
Conservação	Área de Unidades de Proteção Integral	UC_INTEGRAL	ICMBio
Ambiental	Número de Focos de Calor	FOCOSCALOR	BDQueimadas / INPE
Economia	Produto Interno Bruto	PIB	SIDRA / IBGE (2020-2021)

Fonte: Elaboração própria, 2025.

Os dados e informações das variáveis explicativas, também são dos anos de 2020 a 2023, e foram obtidos de fontes diversas, a saber: O Produto Interno Bruto (PIB) municipal, o Índice de Desenvolvimento Humano Municipal (IDHM), a área referente à Produção agrícola municipal, área plantada de cacau, número de bovinos, número de habitantes (estimativas dos anos de 2020 e 2021), Censo 2022, que foram obtidos do Sistema IBGE de Recuperação Automática (SIDRA), do IBGE. Os arquivos vetoriais dos limites municipais dos 194 municípios foram adquiridos também pelo IBGE.

Ademais, foram utilizadas como variáveis resposta a extensão da malha viária, do Departamento Nacional de Infraestrutura de Transportes (DNIT), áreas protegidas do

Instituto Chico Mendes de Conservação da Biodiversidade (ICMBio), número de focos de calor do BDQueimadas do Instituto Nacional de Pesquisas Espaciais (INPE). O uso de abreviações na Tabela 1 objetivou reduzir a complexidade na escrita dos termos empregados.

2.2.2. Processamento e Análises Estatísticas

Os dados foram organizados em tabelas e incorporados aos arquivos vetoriais dos municípios, utilizando o código municipal fornecido pelo IBGE. Os dados e informações foram padronizados por área (km²) e população (conforme aplicável) e transformados na média do período estudado.

As bases de dados utilizadas apresentam diferentes naturezas e escalas espaciais de origem, incluindo informações derivadas de sensoriamento remoto, dados vetoriais e estatísticas socioeconômicas produzidas em nível administrativo. Para fins de integração e aplicação dos modelos de regressão, todas as variáveis foram compatibilizadas à unidade territorial do município, por meio de procedimentos de agregação espacial e padronização, conforme descrito anteriormente. Essa mudança de suporte espacial implica generalização dos fenômenos originalmente contínuos ou pontuais e redução da variabilidade intra-municipal, estando associada ao denominado Problema da Unidade de Área Modificável (Modifiable Areal Unit Problem – MAUP), no qual os resultados analíticos podem variar em função da escala e da forma das unidades de agregação (Fotheringham *et al.*, 2002). Assim, os resultados obtidos devem ser interpretados como representativos de padrões regionais entre municípios, não captando a heterogeneidade e os processos que ocorrem no interior das unidades municipais de análise.

A pesquisa foi sustentada estatisticamente pela Regressão Geograficamente Ponderada (RGP). A aplicação desta metodologia exige o uso de métodos estatísticos complementares, descritos no próximo tópico, incluindo procedimentos de validação e análise de desempenho, como os Coeficientes de Determinação (R^2 e R^2 ajustado) e o Fator de Inflação da Variância (VIF), devido sua aplicação relativamente facilitada.

2.2.3. Regressão por Mínimos Quadrados Ordinários

A análise de regressão espacial, de modo geral, consiste em um método estatístico utilizado para examinar a relação entre uma variável dependente e um conjunto de variáveis independentes, ou preditoras (Druck, 2004). Desse modo, um dos processos mais

utilizados para estimação desses coeficientes é o método por Mínimos Quadrados Ordinários (MQO).

O MQO é empregado para ajustar modelos lineares múltiplos e identificar padrões amplos de ocorrência (Gujarati, 2011; Wooldridge, 2018). Este modelo fornece uma perspectiva global ao estimar um único conjunto de coeficientes para toda a área de estudo (Fotheringham *et al.*, 2002).

O modelo é expresso conforme a Equação 1:

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_n X_n + \varepsilon \text{ (Equação 1)}$$

Em que, “Y” é a variável dependente (área antropizada), “ β_0 ” é o intercepto, “ $\beta_1, \beta_2, \dots, \beta_n$ ”, são os coeficientes de regressão, “ $X_1, X_2, \dots, X_n$ ”, são as variáveis explicativas e “ ε ” é o termo de erro aleatório.

Inicialmente, um modelo de regressão linear múltipla foi ajustado usando o método de Mínimos Quadrados Ordinários (MQO) para identificar os fatores globais associados à antropização. Após o ajuste para prever a AREA_ANTRO a partir das variáveis explicativas, foram realizadas análises de diagnóstico dos resíduos para verificar o cumprimento dos pressupostos da regressão. A partir deste modelo, os resíduos (e_i) para cada observação são calculados como a diferença entre o valor real e o valor previsto ($e_i = y_i - \hat{y}_i$) (Gauss, 1809). Os resíduos obtidos são elevados ao quadrado (e_i^2), e seu resultado é usado como uma estimativa da variância do erro para cada observação.

Em sequência, uma nova regressão (auxiliar) é construída, na qual os resíduos ao quadrado (e_i^2) se tornam a variável dependente, e as variáveis explicativas originais (POD_AGRI, MED_BOV, etc.) são as preditoras. O objetivo é verificar se as variáveis explicativas são capazes de prever a variância dos erros. Um pressuposto fundamental do MQO é que os resíduos (erros) do modelo sigam uma distribuição normal. A violação deste pressuposto pode afetar a validade dos testes de hipóteses (p-valores) para os coeficientes (Hair *et al.*, 2009; Gujarati; Porter, 2011).

Para verificar esta condição, foi aplicado o teste de Shapiro-Wilk (W). O teste funciona da seguinte maneira: é feito o cálculo dos resíduos (e_i) a partir do modelo de regressão ajustado; os resíduos são ordenados do menor para o maior; e o cálculo da estatística W, que compara os resíduos ordenados com os valores que seriam esperados se eles viessem de uma distribuição normal (Shapiro e Wilk, 1965; Royston, 1982; Field, 2009).

A fórmula geral é:

$$W = \frac{(\sum_{i=1}^n a_i e_{(i)})^2}{\sum_{i=1}^n (e_i - \bar{e})^2} \quad (\text{Equação 2})$$

Em que, “ $e_{(i)}$ ” são os resíduos ordenados, “ $\bar{e}$ ” é a média dos resíduos (que é sempre zero), e os coeficientes “ a_i ” são constantes derivadas da média e variância da distribuição normal. A estatística W varia de 0 a 1 e um valor próximo de 1 indica que os dados se assemelham a uma distribuição normal. O teste fornece um p-valor baseado na estatística W (Field, 2009).

Por fim, a detecção de autocorrelação espacial significativa nos resíduos do MQO indica que o modelo global não está capturando toda a estrutura espacial dos dados. Tal condição justifica o uso da Regressão Geograficamente Ponderada (RGP), uma técnica local projetada para lidar com a não estacionariedade e modelar como as relações entre as variáveis ao longo do território mudam.

2.2.4. Regressão Geograficamente Ponderada

Na sequência, foi aplicado o modelo da Regressão Geograficamente Ponderada (RGP), que tem sido utilizado para examinar as relações espacialmente explícitas entre a frequência dos fenômenos analisados e os fatores espaciais explicativos (Martins; Vaz, 2019), com o diferencial de indicação do R^2 local. Essa abordagem é indicada para evidenciar a não estacionariedade espacial local (no caso, para cada município), ao permitir que os coeficientes de regressão variem localmente no espaço geográfico (Que *et al.*, 2020).

Segundo Martins *et al.* (2024), o uso de modelos robustos de regressão é fundamental para uma compreensão mais profunda dos fatores condicionantes de diversos fenômenos geográficos (Jones *et al.*, 2022). Dentre os modelos existentes, identifica-se a RGP, que é de ampla aplicação (Comber *et al.*, 2023; Liu, *et al.*, 2024; Kiani, *et al.*, 2024).

Apesar da importância da RGP e sua ampla aplicação, recomenda-se como passo inicial, a aplicação de algum método de regressão global para estimar coeficientes de regressão (Nakaya *et al.*, 2009; Pebesma e Bivand, 2023).

Com as variáveis identificadas na análise MQO, aplicou-se a RGP, que é uma técnica exploratória cujo objetivo principal é identificar onde ocorrem variações espaciais nos coeficientes de regressão (Fotheringham e Oshan, 2020). Ou seja, onde os coeficientes locais se diferenciam dos valores globais no mapa (Huang *et al.*, 2023). O Modelo (equação 3) para o método RGP é:

$$Y_i = \beta_0(u_i, v_i) + \beta_1(u_i, v_i)X_{1i} + \beta_2(u_i, v_i)X_{2i} + \dots + \beta_n(u_i, v_i)X_{ni} + \varepsilon_i \text{ (equação 3)}$$

Em que, “(u_i, v_i)” são coordenadas geográficas do ponto i, “β₀(u_i, v_i), β₁(u_i, v_i), ..., β_n(u_i, v_i)”, são coeficientes locais, “Y_i”, é o valor da variável dependente no ponto “i” e “ε_i” é o termo de erro do ponto “i”.

A RGP permite avaliar variações espaciais nos coeficientes e identificar onde os efeitos locais diferem dos resultados globais. Após a constatação de autocorrelação espacial nos resíduos do modelo MQO, a análise prosseguiu com a aplicação da RGP. Diferente do MQO, que estima um único coeficiente global para cada variável, a RGP é uma técnica de modelagem local que ajusta uma equação de regressão para cada observação (município) no conjunto de dados. Isso é feito ponderando as observações vizinhas, de modo que aquelas mais próximas ao município em análise tenham maior influência no cálculo dos seus coeficientes locais. Essa abordagem permite que as relações entre a área antropizada e suas variáveis explicativas variem espacialmente, tratando a não estacionariedade identificada nos diagnósticos. A calibração e validação do modelo RGP exigem a definição de parâmetros e a realização de diagnósticos específicos (Fotheringham e Oshan, 2020).

2.3.4 Métricas de Validação do Modelo

A comparação entre os modelos utilizados foi realizada com base nos valores do Coeficiente de Determinação Ajustado (R² ajust.) e o valor do Fator de Inflação da Variância (VIF). O R² mede a proporção da variância na variável dependente que é previsível a partir das variáveis independentes (Ozili, 2023). O modelo de Mínimos Quadrados Ordinários (MQO) produz um valor de R² ajustado global e a Regressão Geograficamente Ponderada (RGP), um modelo para cada área, no caso, cada município. A equação do R² ajustado consta na Equação 4.

$$R_{ajust.}^2 = 1 - \left[\frac{(1-R^2)(n-1)}{n-k-1} \right] \quad \text{(Equação 4)}$$

Na equação descrita acima, R²_{ajust.} representa o coeficiente de determinação ajustado, enquanto R² corresponde ao coeficiente de determinação simples derivado do valor original da amostra. O parâmetro n denota o tamanho da amostra, expressando o número total de observações ou municípios analisados, ao passo que k refere-se ao número de variáveis

independentes, ou preditoras, incorporados ao modelo estatístico para a explicação da variável dependente.

De modo geral, o R^2 mede a proporção da variância da variável dependente que é explicada pelos preditores no entorno de cada localidade. A análise do mapa de R^2 local permite identificar as áreas onde o modelo tem um poder explicativo alto e onde ele é menos eficaz (Fotheringham e Oshan, 2020).

Além da aderência, a estabilidade do modelo foi verificada via Fator de Inflação da Variância (VIF), métrica que quantifica o grau de multicolinearidade presente em um modelo de regressão (Shrestha, 2020). O critério VIF é utilizado para rastrear e identificar a robustez dos modelos (Wu, 2020), adotando-se nesta pesquisa um valor limiar inferior a 8, visto que valores excessivamente elevados indicam redundância de informações e podem comprometer a confiabilidade dos coeficientes estimados.

Conforme expresso na Equação 5, o VIF é calculado para cada variável pela razão entre a unidade e o complemento do coeficiente de determinação ($1 - R^2$), sendo definido por:

$$VIF = \frac{1}{1-R^2} \quad (\text{Equação 5})$$

Na qual, o parâmetro R^2 refere-se especificamente ao coeficiente de determinação obtido ao regredir a variável independente de interesse contra todas as demais variáveis explicativas remanescentes no modelo, permitindo identificar o quanto da variância de um preditor é explicada pelos demais.

3. RESULTADOS E DISCUSSÃO

O resultado da análise de regressão global com os respectivos coeficientes de regressão, valor t e significância dos coeficientes, estão apresentados na Tabela 2. O VIF é apresentado para identificação da existência de multicolinearidade, como referido na metodologia.

Com base nessa observação, as covariáveis determinadas pelo modelo foram: FOCOSCALOR, MED_BOV e MED_POP (todas têm um valor de p - 0,01; Tabela 2). Os coeficientes para as variáveis FOCOSCALOR, MED_BOV foram positivos, o que significa que há associação positiva com a área média antropizada no município. Ao contrário, para a variável MED_POP foram negativas, ou seja, associação negativa com a antropização.

Isso significa que o aumento da densidade demográfica não implica aumento da antropização. O que corrobora a dificuldade de representar, por meio de variáveis quantitativas, dimensões humanas de natureza difusa e dinâmica, como governança territorial, conflitos fundiários, práticas socioculturais e modos de vida locais.

Tabela 2: Resumo dos ajustes de modelo e métricas de desempenho para a regressão MQO.

Variáveis	Estimativa	T-statistic	Value-P	VIF
FOCOSCALOR	24,47	1,926	0,055704*	1,544801
MED_BOV	5,244	7,722	7,09x10 ⁻¹³ *	2,020869
MED_POP	-10.170	-3.605	0,000402*	1,826718
KM_ROD	1,477	1,449	0,149043	1,495461
POD_AGRI	-1,020	-0,889	0,375041	7,228501
UC_SUST	0,05945	1,166	0,245304	7,390656
UC_INTEGRAL	0,7825	0,633	0,527742	1,046158
CACAU	15,37	0,218	0,827972	1,324645
R ²	0.4017			
R ² ajustado	0.3757			

Foi identificado que o valor R² ajustado do MQO é de 0.3757 (0,38), já o da RGP foi de 0,5990178 (0,60), o que significa que a RGP explicou 60% das variações na área antropizada. O valor AIC da RGP foi de 5733.281, inferior ao AIC da regressão MQO, que foi de 5841.784. Assim, quanto menor o AIC, melhor o modelo da RGP explica as variações na área antropizada. Em geral, houve um ganho significativo ao usar o modelo RGP.

Tabela 3: Coeficientes do modelo RGP para a área antropizada.

Variável	Min	1st Qu	Median	3rd Qu	Max
FOCOSCALOR	-114,53	0,093234	31,479	52,947	181,57
MED_BOV	-3,5983	3,4662	4,7883	8,1496	16,988
MED_POP	-23.548	-15.027	-10.427	-5.379,3	10.706
R ²	0.6921731				
R ² ajustado	0.5990178				

Contudo, apesar desta visão geral, os testes de diagnóstico revelaram limitações críticas no modelo MQO. A análise gráfica dos resíduos indicou a presença de heterocedasticidade e, mais importante, o resultado do teste I de Moran apontou uma autocorrelação espacial positiva e significativa nos resíduos ($I = 0.33$, $p < 0.01$). Esse resultado viola um pressuposto chave da regressão linear e demonstra que o modelo global não consegue capturar a estrutura geográfica dos dados, justificando a necessidade de uma abordagem local.

A calibração do modelo RGP foi realizada utilizando um kernel adaptativo e minimizando o critério AICc, o que determinou um número ótimo de 45 vizinhos para cada regressão local. Conforme afirma Martins *et al.* (2024), o modelo RGP tem uma grande

vantagem em possibilitar a análise utilizando o R^2 local, destacando as áreas em que melhor desempenhou. Com efeito, é possível obter uma visualização espacial do desempenho do modelo em explicar a área antropizada no Bioma Mata Atlântica, no Estado da Bahia (Figura 3). Assim, é possível observar que os maiores valores de R^2 foram encontrados nos municípios na porção sul e sudeste da área de Mata Atlântica, na Bahia, onde o valor R^2 foi de 0,69. Em contrapartida, a porção da área de estudo, os valores e o R^2 foram menores.

Os valores de R^2 , coeficientes para as variáveis ambientais FOCOSCALOR e MED_BOV estão representados na Figura 3 (A, B e C). Esses índices indicam a presença de não estacionariedade espacial, ou seja, o fato de que a relação entre as variáveis explicativas e a área antropizada varia significativamente ao longo do espaço geográfico. De modo que, fatores como número de bovinos, focos de calor exercem influências diferenciadas dependendo da localização.

As diferenças encontradas corroboram a relevância do uso de modelos como a RGP em análises geográficas, já que permite capturar padrões específicos, que o modelo global MQO não sinaliza. Este tipo de regressão fornece um conjunto de coeficientes estimados ao longo de uma curva de distribuição. Sendo possível, dessa forma, visualizar as variações nos coeficientes ao longo do espaço analisado para cada variável, e são esses coeficientes que sintetizam a heterogeneidade intrínseca aos fenômenos estudados (Schmitz, 2014). O modelo RGP mostrou-se mais aderente e superior às modelagens anteriores em todas as variáveis, com valores VIF dentro dos limites recomendados.

A principal contribuição da RGP foi revelar a não estacionariedade espacial das relações, ou seja, a influência de cada variável muda significativamente ao longo do território. Contudo, deve-se ressaltar que as relações espaciais aqui identificadas são condicionadas pela unidade de análise municipal, o que implica um processo de agregação e generalização dos fenômenos. As variáveis originalmente contínuas ou pontuais foram compatibilizadas a esse suporte espacial, reduzindo a variabilidade intra-municipal e produzindo padrões médios por município. Tal procedimento está associado ao Problema da Unidade de Área Modificável (Modifiable Areal Unit Problem – MAUP), segundo o qual os resultados estatísticos e cartográficos podem variar em função da escala e da forma das unidades de agregação (Fotheringham *et al.*, 2002). Assim, os mapas de R^2 local e de coeficientes devem ser interpretados como representações de tendências regionais e contrastes intermunicipais, e não como representação de dinâmicas locais, as quais exigiriam bases de dados e abordagens metodológicas distintas.




Figura 3 - A - R^2 local, B - Coeficientes para variável focos de calor e C - coeficientes da variável número de bovinos.

Fonte: Elaboração própria, 2025.

Nesse contexto, ainda que os dados do MapBiomas possuam resolução espacial de 30 metros, sua compatibilização entre a malha municipal e as variáveis explicativas resulta em uma representação agregada das dinâmicas locais. Na prática, um mesmo município pode abrigar simultaneamente frentes ativas de antropização e áreas sob regimes rigorosos de conservação, realidades que acabam diluídas em um único valor médio. Essa diluição contribui para explicar, por exemplo, a baixa significância estatística observada para as variáveis de conservação (UC_SUST e UC_INTEGRAL) no modelo global, cujos efeitos protetivos locais podem ter sido ocultados pela escala de agregação adotada.

Desse modo, a espacialização aqui apresentada deve ser interpretada com cautela, pois, embora revele contrastes intermunicipais e padrões macroestruturais, apresenta limitações para subsidiar ações de manejo em escala de detalhe. Essa generalização espacial constitui um ponto significativo que deve orientar investigações futuras, nas quais a adoção de unidades de análise mais refinadas será fundamental para revelar as nuances da antropização em nível intra-municipal. Assim, a análise do R^2 local é essencial para complementar esses achados, mostrando as áreas onde o conjunto de variáveis teve maior ou menor poder preditivo, e validando que os processos de antropização na Mata Atlântica baiana são geograficamente heterogêneos.

Apesar dessas limitações, a modelagem local permitiu identificar disparidades regionais expressivas nos principais vetores de pressão sobre a Mata Atlântica baiana. A Área de Produção Agrícola (POD_AGRI) e os Focos de Calor (FOCOSCALOR) apresentaram seus maiores coeficientes na porção oeste da área de estudo, na fronteira de expansão agrícola com o Cerrado. Isso indica que a conversão de novas terras é um motor primário de antropização nesta região. Segundo Martins (2024), nessa área, na transição para o Cerrado, apresenta agrupamentos expressivos de áreas queimadas. Atualmente, a porção oeste do estado da Bahia integra a região conhecida como MATOPIBA — acrônimo de Maranhão, Tocantins, Piauí e Bahia — que, desde a década de 1980, vem sendo progressivamente incorporada à produção agropecuária, consolidando-se como uma das principais fronteiras agrícolas do Brasil (Bolfe *et al.*, 2016).

Em contraste, a pressão antrópica em outras porções da Mata Atlântica baiana apresenta dinâmica distinta, fortemente vinculada à pecuária extensiva. Nesse sentido, o Número de Bovinos (MED_BOV) mostrou um impacto visivelmente mais forte na região do Extremo Sul, corroborando a conhecida vocação desta área para a expansão de pastagens, muitas vezes em detrimento de remanescentes florestais. Esse resultado corrobora aquele apresentado por Guimarães *et al.* (2023), que elencou a pecuária como motivador para a área de desmatamento na Mata Atlântica, portanto contribui diretamente para o processo de antropização. A expansão de pastagens para criação de gado demanda a remoção da vegetação nativa, resultando na fragmentação dos habitats, perda de biodiversidade e alteração dos ciclos ecológicos. Esse uso intensivo do solo, frequentemente associado a práticas extensivas e de baixa sustentabilidade, tem provocado impactos significativos sobre os ecossistemas da Mata Atlântica.

A atuação desses vetores de pressão é potencializada pela infraestrutura de transportes. A Malha Viária (KM_ROD) apresentou seus maiores coeficientes ao longo dos principais eixos rodoviários e nas proximidades da região metropolitana de Salvador, atuando como um vetor que facilita o acesso e a intensificação da ocupação humana e econômica. Essa heterogeneidade nos coeficientes reforça a inadequação de um modelo global e a necessidade de análises que considerem o contexto geográfico para um planejamento territorial eficaz.

Em síntese, os resultados demonstram que os processos de antropização na Mata Atlântica baiana são espacialmente heterogêneos e condicionados por dinâmicas regionais distintas, associadas à expansão agrícola, à pecuária extensiva e à acessibilidade territorial. A comparação entre o MQO e a RGP evidenciou a superioridade da abordagem local na

captura da não estacionariedade espacial das relações analisadas, ainda que sob as limitações impostas pela escala municipal de agregação. Esses achados reforçam a importância de modelos sensíveis ao contexto geográfico como ferramentas analíticas essenciais.

Os resultados sugerem, por exemplo, que, enquanto a porção oeste do estado apresenta maior associação com variáveis relacionadas à expansão da fronteira agrícola e à ocorrência de focos de calor, o Extremo Sul tende a concentrar relações mais intensas com a atividade pecuária. Esses padrões indicam que diferentes regiões podem demandar estratégias diferenciadas de gestão territorial, incluindo ações de controle da expansão agropecuária, manejo mais sustentável das atividades produtivas e recuperação de fragmentos florestais. Nesse sentido, a modelagem espacial aqui apresentada contribui para a identificação de áreas prioritárias e para a compreensão de contrastes regionais, oferecendo subsídios analíticos para o planejamento ambiental e a formulação de políticas públicas no estado.

4. CONCLUSÕES

Este estudo demonstrou que os fatores associados à antropização na Mata Atlântica baiana não são uniformes em todo o território analisado. Quanto às variáveis aqui consideradas, o número de bovinos e focos de calor foram as mais significativas. Desse modo, os fatores que impulsionam a transformação do meio natural variam conforme a localidade. No entanto, o fato de que o número de bovinos e os focos de calor se destacarem como variáveis mais significativas sugere que a pecuária é vetor central de antropização, já que o número de bovinos aponta para a expansão da atividade pecuária, que muitas vezes demanda desmatamento para formação de pastagens.

Ademais, a presença de focos de calor está geralmente associada a queimadas, que podem ser intencionais, para limpeza de áreas agrícolas ou de pasto acidentais ou descontroladas, em áreas vulneráveis. A correlação com a antropização pode indicar que as queimadas são parte do processo de modificação da paisagem natural, seja na abertura de novas áreas ou na manutenção de áreas já alteradas. Da perspectiva metodológica, a superioridade do modelo RGP sobre o modelo MQO confirmou a existência de não estacionariedade espacial, provando que a influência de cada fator varia geograficamente. Considera-se esse resultado consistente, refletindo a natureza heterogênea do território analisado, composto por 194 municípios com diferentes dinâmicas territoriais, socioeconômicas e ambientais.

A aplicação da Regressão Geograficamente Ponderada (RGP) vem evidenciando seu potencial em revelar padrões espaciais complexos e não estacionários, mesmo em contextos de dados limitados. É importante ressaltar que as variáveis físicas podem ser mais diretamente quantificadas e incorporadas aos modelos, enquanto os aspectos da geografia humana (como governança ambiental, mobilidade populacional e capacidade territorial, dinâmicas socioeconômicas, demográficas e culturais, etc.) desafiam a mensuração objetiva, por sua natureza multifacetada, dinâmica e profundamente enraizada nas especificidades de cada território.

Essa assimetria metodológica, historicamente presente na dicotomia entre geografia física e humana, impõe desafios à representação estatística dos fenômenos territoriais. Isto posto, pesquisas dessa natureza corroboram com a ampliação e qualificação das bases de dados, nas quais o uso de RGP pode contribuir significativamente para análises espaciais mais sensíveis à heterogeneidade dos territórios.

REFERÊNCIAS

BOLFE, E. L.; VICTÓRIA, D. C.; CONTINI, E.; BAYMA-SILVA, G.; SPINELLI-ARAÚJO, L.; GOMES, D. Matopiba em crescimento agrícola: Aspectos territoriais e socioeconômicos. **Revista de Política Agrícola**, v. 25, n. 4, p. 38-62, 2016.

COELHO-JUNIOR, M. G.; OLIVEIRA, A. L.; SILVA NETO, E. C.; CASTOR NETO, T. C.; TAVARES, A. A. O.; BASSO, V. M.; TURETTA, A. P. D.; PERKINS, P. E.; CARVALHO, A. G. Exploring plural values of ecosystem services: Local peoples' perceptions and implications for protected area management in the Atlantic forest of Brazil. **Sustainability**, v. 13, n. 3, p. 1019, 2021.

COMBER, S.; HARRIS, P.; BRUNSDON, C. A multiscale RGP-RF hybrid approach for spatial prediction of soil properties. **Remote Sensing**, v. 15, n. 8, p. 2149, 2023.

COSTA, D. S.; NUVOLONI, F. M.; LOPES, E. R. N. **Mata Atlântica: a história que a história não contou**. Ilhéus: Editus, 2024. 121p.

DRUCK, S.; CARVALHO, M. S.; CÂMARA, G.; MONTEIRO, A. M. V. **Análise espacial de dados geográficos**. Brasília: **Embrapa**, 2004.

FIELD, A. **Descobrendo a Estatística Usando o SPSS**. Porto Alegre: Artmed, 2009. 688p.
FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. Regressão Geograficamente Ponderada: The Analysis of Spatially Varying Relationships. Chichester: **Wiley**, 2002. 288p.

FOTHERINGHAM, A. S.; OSHAN, T. M. (Eds.). Regressão Geograficamente Ponderada: the analysis of spatially varying relationships. Boca Raton: **CRC Press**, 2020. 288p.

FREITAS, W. K.; MAGALHÃES, L. M. S.; SANTANA, C. A. A.; PEREIRA JUNIOR, E. R.; SOUZA, L. C. M.; TOLEDO, R. A. B.; BEATRIZ ROCHA GARÇÃO, B. R. Atlantic Forest of Brazil: A systematic review. **Urban Forestry & Urban Greening**, v. 48, p. 126555, 2020.

GAUSS, C. F. **Theoria motus corporum coelestium in sectionibus conicis solem ambientium**. Hamburg: F. Perthes e I. H. Besser, 1809. 268p.

GRELLE, C. E. V.; RAJÃO, H.; MARQUES, M. C. M. The Future of the Brazilian Atlantic Forest. In: The Atlantic Forest: History, Biodiversity, Threats and Opportunities of the Mega-Diverse Forest. Cham: **Springer International Publishing**, 2021. p. 487-503.

GUIMARÃES, P. O.; SANTOS, A. M.; SILVA, C. F. A.; RUDKE, A. P.; NUNES, F. G.; LISBOA, G. S.; FERNANDES, M. S. Análise espacial dos fatores condicionantes do desmatamento do Bioma Mata Atlântica/Brasil. **Revista GEOgrafias**,

GUJARATI, D. N.; PORTER, D. C. **Econometria básica**. Porto Alegre: AMGH, 2011. 920p.

HAIR JÚNIOR, J. F.; BLACK, W. C.; BABIN, B. J.; ANDERSON, R. E.; TATHAM, R. L. **Análise Multivariada de Dados**. Porto Alegre: Bookman, 2009. 688p.

HUANG, Z.; LI, S.; PENG, Y.; GAO, F. Spatial non-stationarity of influencing factors of China's county economic development based on a multiscale Regressão Geograficamente Ponderada model. **ISPRS International Journal of Geo-Information**, v. 12, n. 3, p. 109, 2023.

IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. **Áreas Territoriais**. Rio de Janeiro: IBGE, 2023. Disponível em: <https://www.ibge.gov.br>. Acesso em 02 fev. 2025.

JONES, M.; HARRIS, P.; BRUNSDON, C. Robust Regressão Geograficamente Ponderada: A review and software implementation. **Transactions in GIS**, v. 26, n. 3, p. 1228-1249, 2022.

KIANI, F.; SOLTANI, A.; MESBAH, M. Modeling the spatial variation of traffic accident severity using Regressão Geograficamente Ponderada. **Journal of Transport & Health**, v. 34, p. 101723, 2024.

LIU, Y.; ZHANG, X.; TU, W.; LI, J. A geographically and temporally weighted regression model to explore the spatiotemporal drivers of urban growth. **International Journal of Geographical Information Science**, v. 38, n. 1, p. 1-25, 2024.

MAPBIOMAS. **Coleção 9.0 da Série Anual de Mapas de Cobertura e Uso de Solo do Brasil**. São Paulo: MapBiomias, 2024. Disponível em: <https://mapbiomas.org>. Acesso em: 22 jul. 2025.

MARQUES, M. C. M.; TRINDADE, W.; BOHN, A.; GRELLE, C. E. V. The Atlantic Forest: an introduction to the megadiverse forest of South America. In: **The Atlantic Forest**: History, biodiversity, threats and opportunities of the mega-diverse Forest. Cham: Springer International Publishing, 2021. p. 3-23.

MARTINS, S. F. S.; SANTOS, A. M.; SILVA, C. F. A.; RUDKE, A. P.; ALVARADO, S. T.; MELO, J. L. S. The drivers of fire in the Caatinga Biome in Brazil. In: **Forest Ecology and Management**, v. 572, p. 122260–122260, 2024.

MARTINS, V. F.; VAZ, E. Modelagem espacial de incêndios florestais em Portugal utilizando Regressão Geograficamente Ponderada. **Finisterra**, v. 54, n. 111, p. 89-110, 2019.

NAKAYA, T.; CHARLTON, M.; BRUNSDON, C.; FOTHERINGHAM, A. S. **RGP 4: the software for Regressão Geograficamente Ponderada analysis**. Quioto: RGP-GIST, Ritsumeikan University, 2009.

OLIVEIRA, U.; LIMA, R. A. F.; LEWINSOHN, T. M.; METZGER, J. P. Integração de bancos de dados para o planejamento da conservação e restauração da Mata Atlântica. **Perspectives in Ecology and Conservation**, v. 20, n. 2, p. 127-136, 2022.

OZILI, P. K. The acceptable R-square in empirical modelling for social science research. In: **Social research methodology and publishing results: A guide to non-native English speakers**. IGI global, 2023. p. 134-143.

PEBESMA, E.; BIVAND, R. **Spatial Data Science with R**. Boca Raton: CRC Press, 2023. 300p.

QGIS DEVELOPMENT TEAM. **QGIS Geographic Information System**. Open Source Geospatial Foundation Project, 2023. Disponível em: <http://qgis.osgeo.org>. Acesso em: 02 fev. 2025.

QUE, X.; ZHU, A. X.; ZHOU, C. Z.; ZHANG, J.; ZHANG, Y.; ZHANG, X. Introducing spatial-temporal weighted regression (STWR): a local space-time predictive model for spatial nonstationarity. **Geoscientific Model Development**, v. 13, n. 12, p. 6149–6168, 2020.

R CORE TEAM. **R: A Language and Environment for Statistical Computing**. Viena: R Foundation for Statistical Computing, 2025. Disponível em: <https://www.R-project.org>. Acesso em: 02 fev. 2025.

ROMANELLI, J. P.; MELI, P.; SANTOS, J. P. B.; JACOB, I. N. Biodiversity responses to restoration across the Brazilian Atlantic Forest. **Science of The Total Environment**, v. 821, p. 153403, 2022.

ROYSTON, P. An extension of Shapiro and Wilk's W test for normality to large samples. *Journal of the Royal Statistical Society: Series C (Applied Statistics)*, v. 31, n. 2, p. 115-124, 1982.

SAMPAIO, S. A.; DE OLIVEIRA, R. C.; SOUZA, S. O. Dinâmica de uso e ocupação das terras na região Costa do Dendê, Estado da Bahia, Brasil, Entre 1985 E 2023: Uma análise dos reflexos socioeconômicos e ambientais em escala regional. **Caminhos de Geografia, Uberlândia**, v. 25, n. 99, p. 114-132, 2024.

SANTOS, A. M.; SILVA, C. F. A. ALMEIDA JUNIOR, P. M.; RUDKE, A. P.; S. N. MELO. Deforestation drivers in the Brazilian Amazon: assessing new spatial predictors. **Journal of environmental management**, v. 294, p. 113020, 2021.

SCARANO, F. R. Ecologia: do indivíduo aos ecossistemas. Rio de Janeiro: Guanabara Koogan, 2014. 752p.

SCHMITZ, A. L. **Heterogeneidade espacial dos determinantes do desmatamento na Amazônia Legal**: uma análise com regressão geograficamente ponderada. 2014. 92 f. Tese (Doutorado em Desenvolvimento Econômico) - Universidade Federal do Paraná, Curitiba, 2014.

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, v. 52, n. 3/4, p. 591-611, 1965.

SHRESTHA, N. Detecting multicollinearity in regression analysis. **American journal of applied mathematics and statistics**, v. 8, n. 2, p. 39-42, 2020.

SILVA, J. M. C.; OLIVEIRA, A. P.; YOUNG, C. E. F. O conceito de antropização e sua aplicação em estudos de paisagem. In: CONGRESSO BRASILEIRO DE ECOLOGIA DE PAISAGENS, 14., 2018, Campinas. **Anais...** Campinas: IALE-BR, 2018. p. 1-5.

SILVEIRA, J. G.; OLIVEIRA NETO, S. N.; CANTO, A. C. B.; LEITE, F. F. G. D.; CORDEIRO, F. R.; ASSAD, L. T.; SILVA, G. C. C.; MARQUES, R. O.; DALARME, M. S. L.; RODRIGUES, R. A. R. Land use, land cover change and sustainable intensification of agriculture and livestock in the Amazon and the Atlantic Forest in Brazil. **Sustainability**, v. 14, n. 5, p. 2563, 2022.

SOLÓRZANO, A.; BRASIL, L. S. C. A.; OLIVEIRA, R. R. The Atlantic Forest ecological history: From pre-colonial times to the Anthropocene. In: **The Atlantic forest**: History, biodiversity, threats and opportunities of the mega-diverse forest. Cham: Springer International Publishing, 2021. p. 25-44.

SOUZA JR., C. M.; ROSA, M.; ALENCAR, A.; AZEVEDO, T. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. **Remote Sensing**, v. 12, n. 17, p. 2735, 2020.

WOOLDRIDGE, J. M. **Introdução à econometria**: uma abordagem moderna. 6. ed. São Paulo: Cengage Learning, 2018. 878p.

WU, D. Spatially and temporally varying relationships between ecological footprint and influencing factors in China's provinces Using Regressão Geograficamente Ponderada (RGP). **Journal of Cleaner Production**, v. 261, p. 121089, 2020.

Recebido: 30/07/2025

Aceito: 16/03/2026