



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA E INOVAÇÃO
INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS

MODELAGEM DA RELAÇÃO ESPACIAL ENTRE ÍNDICES FLORESTAIS E BIOMASSA FLORESTAL EM CRUZEIRO DO SUL, ACRE.

Marcus Vinicius Gonçalves da Silva
Antonio Miguel Vieira Monteiro
Maria Isabel Sobral Escada

Trabalho final para cumprimento
das exigências da disciplina SER-
301 Análise Espacial de Dados Ge-
ográficos, para a conclusão do mes-
trado em Sensoriamento Remoto.

INPE
São José dos Campos
2025

RESUMO

A paisagem florestal amazônica constitui um sistema complexo, moldado ao longo do tempo por processos naturais e pela intensificação das atividades antrópicas, resultando em alterações significativas na estrutura e no funcionamento dos ecossistemas. No município de Cruzeiro do Sul, Acre, essa dinâmica manifesta-se por meio de diferentes formas de uso e ocupação do solo, promovendo distúrbios florestais e afetando a integridade da floresta. Tais modificações refletem-se diretamente na biomassa acima do solo, uma vez que processos de degradação florestal, extração seletiva de madeira e impactos de incêndios reduzem a capacidade de armazenamento de carbono, muitas vezes sem serem plenamente captados por sistemas tradicionais de monitoramento baseados exclusivamente no desmatamento. Nesse contexto, este trabalho teve como objetivo analisar a relação entre a variação da biomassa florestal acima do solo (ΔAGB) e a variação dos valores do Índice de Integridade Florestal (ΔINDIT) e do Índice de Distúrbio Florestal (ΔINDDF) no município de Cruzeiro do Sul, entre os anos de 2014 e 2022, avaliando o potencial desses índices sintéticos como métricas explicativas das alterações biofísicas na estrutura florestal. Para isso, foram utilizados dados espaciais de biomassa e métricas de paisagem organizados em uma grade regular, sobre os quais se aplicaram análises exploratórias espaciais para a identificação de padrões e autocorrelação espacial, seguidas do ajuste de modelos de regressão clássicos e espaciais, incluindo modelos globais de erro espacial (SEM) e modelos locais de Regressão Geograficamente Ponderada (GWR), considerando relações lineares, quadráticas e termos de interação entre os índices. Os resultados indicaram uma perda média de biomassa de $-369,41$ Mg por célula no período analisado, associada a uma redução expressiva da integridade florestal, evidenciada pela diminuição dos valores médios do INDIT, bem como a um aumento moderado nos níveis de distúrbio florestal representados pelo INDDF. Do ponto de vista estatístico, os modelos que incorporaram a interação entre integridade e distúrbio, especialmente a formulação quadrática (INTER_Quad), apresentaram melhor desempenho explicativo, com coeficiente de determinação global de $R^2 = 0,271$ nos modelos SEM e aumento para $R^2 = 0,422$ nos modelos GWR. A análise local indicou que 15,7% das células apresentaram coeficientes estatisticamente significativos, evidenciando a dificuldade em capturar a relação entre distúrbio, integridade florestal e variação da biomassa. Esses resultados confirmam que as relações detectadas, embora presentes, manifestam-se de forma fraca e espacialmente limitada, indicando que a dinâmica da biomassa é modulada por múltiplos fatores além dos índices aqui avaliados. De forma geral, o estudo reforça a relevância de empregar métricas integradas e abordagens espaciais para investigar processos de degradação e para aprimorar o monitoramento ambiental em escala municipal na Amazônia, ainda que se reconheça a necessidade de avanços metodológicos e melhorias nas bases de dados utilizadas.

Palavras-chave: Regressão Espacial. Biomassa Florestal. Distúrbio Florestal. Integridade Florestal.

MODELLING THE SPATIAL RELATIONSHIP BETWEEN FOREST INDICES AND FOREST BIOMASS IN CRUZEIRO DO SUL, ACRE.

ABSTRACT

The Amazonian forest landscape is a complex system, shaped over time by natural processes and the intensification of human activities, resulting in significant changes in the structure and functioning of ecosystems. In the municipality of Cruzeiro do Sul, Acre, this dynamic manifests itself through different forms of land use and occupation, promoting forest disturbances and affecting the integrity of the forest. Such changes are directly reflected in above-ground biomass, since forest degradation processes, selective timber extraction, and the impacts of fires reduce carbon storage capacity, often without being fully captured by traditional monitoring systems based exclusively on deforestation. In this context, this study aimed to analyze the relationship between the variation in above-ground forest biomass (ΔAGB) and the variation in the values of the Forest Integrity Index (ΔINDIT) and the Forest Disturbance Index (ΔINDDF) in the municipality of Cruzeiro do Sul between 2014 and 2022, evaluating the potential of these synthetic indices as metrics explaining biophysical changes in forest structure. To this end, spatial biomass data and landscape metrics organized in a regular grid were used, to which exploratory spatial analyses were applied to identify patterns and spatial autocorrelation, followed by the adjustment of classical and spatial regression models, including global spatial error models (SEM) and local Geographically Weighted Regression (GWR) models, considering linear and quadratic relationships and interaction terms between the indices. The results indicated an average biomass loss of -369.41 Mg per cell in the analyzed period, associated with a significant reduction in forest integrity, evidenced by the decrease in the average INDIT values, as well as a moderate increase in forest disturbance levels represented by the INDDF. From a statistical point of view, the models that incorporated the interaction between integrity and disturbance, especially the quadratic formulation (INTER_Quad), presented better explanatory performance, with an overall coefficient of determination of $R^2 = 0.271$ in the SEM models and an increase to $R^2 = 0.422$ in the GWR models. The local analysis indicated that 15.7% of the cells had statistically significant coefficients, highlighting the difficulty in capturing the relationship between disturbance, forest integrity, and biomass variation. These results confirm that the relationships detected, although present, are weak and spatially limited, indicating that biomass dynamics are modulated by multiple factors beyond the indices evaluated here. Overall, the study reinforces the relevance of using integrated metrics and spatial approaches to investigate degradation processes and improve environmental monitoring at the municipal level in the Amazon, while recognising the need for methodological advances and improvements in the databases used.

Translated with DeepL.com (free version)

Palavras-chave: Spatial Regression. Forest Biomass. Forest Disturbance. Forest Integrity.

LISTA DE FIGURAS

	<u>Pág.</u>
2.1 Área de estudo	3
2.2 Fluxograma metodológico do estudo.	6
3.1 Distribuição da Biomassa (AGB) em Cruzeiro do Sul (2014-2022)	17
3.2 Distribuição do Índice de Integridade florestal (INDIT) em Cruzeiro do Sul (2014-2022)	19
3.3 Distribuição do Índice de Distúrbio florestal (INDDF) em Cruzeiro do Sul (2014-2022)	21
3.4 Comparação dos valores das variáveis florestais: (A) Relação Biomassa vs Distúrbio e (B) Relação Biomassa vs Integridade	23
3.5 Comparação Real vs. Previsto para os modelos SEM.	26
3.6 Comparação Resíduos vs. Previsto.	28
3.7 Distribuição dos valores de R^2 Ajustado do modelo <i>GWR INT_Quad.</i> . .	31
3.8 Distribuição dos valores de β do modelo <i>GWR INT_Quad.</i>	32
3.9 Distribuição das Células GWR Significativas.	33

LISTA DE TABELAS

	<u>Pág.</u>
2.1 Base de dados	5
2.2 Classes de estudo	8
2.3 Indicadores utilizados para o cálculo do INDDF	9
2.4 Indicadores utilizados no cálculo do INDIT	11
3.1 Estatísticas descritivas da Biomassa (AGB) por célula (2km x 2km).	18
3.2 Estatísticas descritivas do Índice de Integridade Florestal (INDIT).	20
3.3 Estatísticas descritivas do Índice de Distúrbio Florestal (INDDF).	22
3.4 Resultados do teste <i>I de Moran Global</i> para as variáveis do estudo.	23
3.5 Resultados dos resíduos do modelo GWR (INTER_Quad).	30
A.1 Fórmulas e valores dos coeficientes dos modelos concorrentes.	43
A.2 Comparação de desempenho e correlação espacial dos modelos globais concorrentes.	44
A.3 Resultados dos testes de normalidade, heterocedasticidade e autocorre- lação espacial.	44

LISTA DE ABREVIATURAS E SIGLAS

Δ AGB	– Variação da Biomassa Acima do Solo
Δ IndAC	– Variação do Indicador de Área Core
Δ IndDM	– Variação do Indicador de Desmatamento Florestal
Δ IndFF	– Variação do Indicador de Fragmentação Florestal
Δ INDDF	– Variação do Índice de Distúrbio
Δ INDIT	– Variação normalizada do Índice de Integridade
Δ IndPF	– Variação do Indicador de Persistência Florestal
Δ IndRG	– Variação do Indicador de Regeneração Florestal
adjRSerr	– Teste LM de Erro Robusto
adjRSlag	– Teste LM de Lag Robusto
AHP	– Processo de Análise Hierárquica (<i>Analytic Hierarchy Process</i>)
AIC	– Critério de Informação de Akaike
AICc	– Critério de Informação de Akaike Corrigido
Área(CI)	– Área da classe de cicatrizes de incêndio
Área(DG)	– Área da classe de degradação florestal
Área(DM)	– Área da classe de desmatamento
Área(FR)	– Área da classe de floresta remanescente
Área(VS)	– Área da classe de vegetação secundária
COMP_FULL_Step	– Modelo de Componentes Completos otimizado por <i>stepwise</i>
COMP_INDDF_Step	– Modelo de Componentes do Distúrbio otimizado por <i>stepwise</i>
COMP_INDIT_Step	– Modelo de Componentes da Integridade otimizado por <i>stepwise</i>
CV	– Validação Cruzada
F _{orig}	– Área de floresta original
FR	– Floresta Remanescente
GWR	– Regressão Geograficamente Ponderada
IndAC	– Indicador de Área Core
IndDG	– Indicador de Degradação Florestal
IndDM	– Indicador de Desmatamento Florestal
IndFC	– Indicador de Conectividade Florestal
IndFF	– Indicador de Fragmentação Florestal
INDDF	– Índice de Distúrbio Florestal
INDDF_Lin	– Modelo Linear do Índice de Distúrbio
INDDF_Quad	– Modelo Quadrático do Índice de Distúrbio
INDIT	– Índice de Integridade Florestal
INDIT_Lin	– Modelo Linear do Índice de Integridade
INDIT_Quad	– Modelo Quadrático do Índice de Integridade
IndPF	– Indicador de Persistência Florestal
IndRG	– Indicador de Regeneração Florestal
INTER_Lin	– Modelo de Interação Linear dos índices
INTER_Quad	– Modelo de Interação Quadrática dos índices
LM-Error	– Dependência de Erro Espacial (Teste LM)
LM-Lag	– Dependência de Lag Espacial (Teste LM)

OLS	– Mínimos Quadrados Ordinários
SAR	– Modelo de Lag Espacial (<i>Spatial Autoregressive Model</i>)
SEM	– Modelo de Erro Espacial (<i>Spatial Error Model</i>)
SWM	– Matriz de Pesos Espaciais (<i>Spatial Weight Matrix</i>)

SUMÁRIO

	<u>Pág.</u>
1 INTRODUÇÃO	1
2 METODOLOGIA	3
2.1 Área de Estudo	3
2.2 Materiais	4
2.3 Métodos	5
2.3.1 Definição da Grade Celular	6
2.3.2 Estimativa da Biomassa Acima do Solo (AGB)	6
2.3.3 Índice de Distúrbio Florestal (INDDF)	8
2.3.4 Índice de Integridade Florestal (INDIT)	10
2.3.5 Diagnóstico de Autocorrelação Espacial	13
2.3.6 Modelagem Espacial Global (SAR/SEM)	14
2.3.7 Modelagem Espacial Local (GWR)	15
3 ANÁLISE E RESULTADOS	17
3.1 Análise das Variáveis florestais	17
3.1.1 Variação da Biomassa acima do solo (ABG)	17
3.1.2 Variação dos Índice de Integridade Florestal	19
3.1.3 Variação dos Índice de Distúrbio Florestal	20
3.1.4 Relação das Variáveis Florestais	22
3.2 Diagnóstico de Autocorrelação Espacial	23
3.3 Modelo Espacial Global	24
3.3.1 Definição do Modelo Espacial Global	24
3.3.2 Desempenho das Diferentes Abordagens para o Modelo Espacial Global	25
3.3.3 Análise Estatística dos Modelos Globais	27
3.3.4 Análise de Resíduos para a Modelagem Espacial Global	27
3.4 Modelagem Local Através de GWR	29
3.4.1 Modelo Local	29
3.4.2 Análise espacial do Modelo GWR INT_Quad	30
4 CONCLUSÕES	35

REFERÊNCIAS BIBLIOGRÁFICAS	37
ANEXO A - DETALHAMENTO DOS MODELOS ESTATÍSTICOS APLICADOS	43

1 INTRODUÇÃO

A paisagem pode ser definida como um elemento complexo, moldado ao longo do tempo e associado a diversos fatores, como a biodiversidade e a intensificação das atividades antrópicas (METZGER et al., 2007). Nesse sentido, a paisagem vinculada à Floresta Amazônica é constantemente modificada por diferentes atividades, principalmente aquelas relacionadas à ocupação das áreas florestais e à exploração dos recursos naturais (LAPOLA et al., 2023; SOUZA et al., 2025). No município de Cruzeiro do Sul, localizado no estado do Acre, essa dinâmica também é evidente, uma vez que distintas atividades produtivas impactam e transformam a paisagem florestal no município (SILVA; SILVA, 2020; CAMELI; SILVA, 2024; SANTOS et al., 2025).

Essas modificações na paisagem se traduzem em alterações biofísicas da floresta. A supressão da vegetação, bem como a degradação florestal, reduzem a biomassa acima do solo, visto que a própria estrutura vegetal, responsável pelo armazenamento de carbono, é diretamente removida ou danificada (BACCINI et al., 2017; GATTI et al., 2021; HEINRICH et al., 2023). Logo, quantificar essa variação nos estoques de biomassa torna-se, uma importante métrica, estando associada a intensidade dos distúrbios florestais, assim como a integridade florestal.

Nesse contexto, os distúrbios florestais são caracterizados por mudanças, no espaço e no tempo, em padrões característicos de um ecossistema, incluindo o ciclo hidrológico, a estocagem de carbono e a cobertura vegetal, entre outros fatores (PICKETT; WHITE, 1985; TURNER; GARDNER, 2008; RODRIGUES, 2024). Por sua vez, a integridade florestal pode ser entendida como a capacidade de um sistema em manter sua estrutura, diversidade e funcionamento, assegurando a provisão sustentável dos serviços ecossistêmicos (GRANTHAM et al., 2020; KARR et al., 2022; RODRIGUES, 2024). Enquanto o conceito de distúrbio está associado ao evento que causa a mudança, o de integridade refere-se ao estado de conservação resultante da floresta (RODRIGUES, 2024).

Contudo, os programas de monitoramento da Amazônia enfrentam dificuldades para captar a totalidade das características associadas aos distúrbios florestais e a integridade florestal (ALMEIDA et al., 2021; RODRIGUES, 2024). Processos como a perda parcial do dossel, a extração seletiva de madeira ou os danos provocados por incêndios são de difícil identificação pelos sistemas de mapeamento (ALMEIDA et al., 2021). Isso acaba por ocultar a perda de biomassa causada por fatores distintos do desmatamento, evidenciando a necessidade de abordagens que considerem, de

forma integrada, os múltiplos elementos que compõem a dinâmica de perturbação e recuperação florestal.

Nesse contexto, indicadores compostos, como o Índice de Distúrbio Florestal e o Índice de Integridade Florestal, propostos por [Rodrigues et al. \(2025\)](#), surgem como alternativas para sintetizar essa complexidade. No entanto, mesmo com a capacidade de representar alterações na paisagem por meio desses índices, ainda se faz necessário verificar se as variações capturadas por esses índices sintéticos se correlacionam com mudanças biofísicas nas florestas, como a variação da biomassa. Outrossim, o recorte temporal para as análises se baseia nos anos do mapeamento de uso e cobertura TerraClass, que fornecem as informações necessárias para a elaboração dos índices florestais, também em anos com maiores valores de desmatamento identificados pelo PRODES no município ([INPE, 2022c](#); [INPE, 2022a](#); [RODRIGUES, 2024](#)).

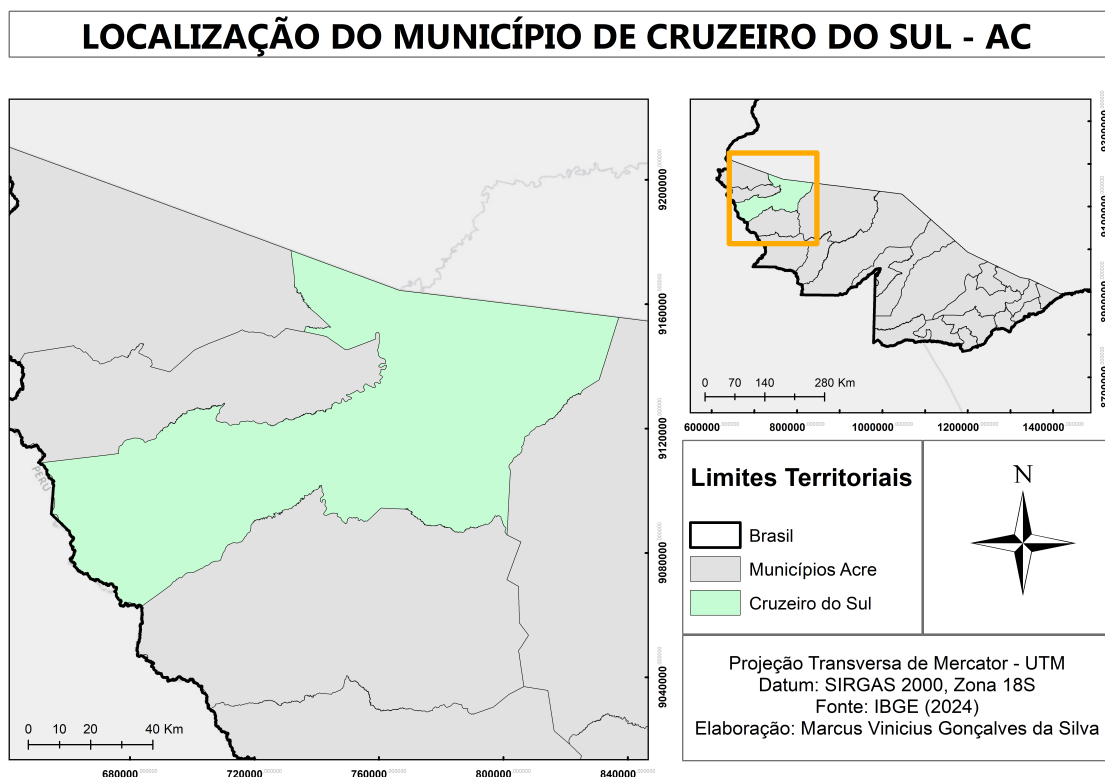
Dessa forma, este trabalho tem como objetivo geral analisar a relação entre a variação da biomassa florestal acima do solo (AGB) e os valores do Índice de Integridade Florestal (INDIT) e do Índice de Distúrbio Florestal (INDDF) no município de Cruzeiro do Sul, Acre entre os anos de 2014 e 2022. Buscando, avaliar o potencial desses índices como métricas explicativas das alterações biofísicas na estrutura florestal.

2 METODOLOGIA

2.1 Área de Estudo

A área de estudo, representada na Figura 2.1, compreende o município de Cruzeiro do Sul, no estado do Acre, localizado na região sudoeste da Amazônia. Esse município possui uma área de aproximadamente 7.925 km² e está situado às margens do Rio Juruá (IBGE, 2022a).

Figura 2.1 - Área de estudo



Fonte: Produção do autor (2025).

Cruzeiro do Sul se destaca como o segundo polo econômico do estado do Acre, sua economia municipal apresenta uma estrutura diversificada, alicerçada principalmente no comércio e na agropecuária, além de práticas extrativistas (SILVA; SILVA, 2020; FREITAS et al., 2011; CAMELI; SILVA, 2024). No meio urbano, predominam o comércio e o setor de serviços públicos, enquanto na zona rural sobressaem a pecuária bovina e agricultura (SILVA; SILVA, 2020; CAMELI; SILVA, 2024).

De acordo com os dados da Produção Agrícola Municipal (PAM), em 2022, aproximadamente 61,65% da área colhida foi destinada ao cultivo da mandioca, totalizando mais de 61 mil toneladas produzidas (IBGE, 2022b). Essa cultura representa o principal produto agrícola do município, com grande participação de agricultores familiares, cuja produção da farinha de mandioca é reconhecida regionalmente pela sua qualidade e importância socioeconômica para a população local (SILVA; SILVA, 2020; FREITAS et al., 2011; CAMELI; SILVA, 2024).

Contudo, apesar dessa predominância histórica, o próprio cultivo da mandioca passa por transformações (SILVA; SILVA, 2020; CAMELI; SILVA, 2024). O artigo de Cameli e Silva (2024) destaca que uma nova dinâmica agrícola vem sendo implementada por migrantes, especialmente de Rondônia, que chegam ao município e introduzem novas culturas, como o café e o cacau, e técnicas de produção distintas. Essa diversificação, a contínua expansão da pecuária, e a busca por novas áreas para cultivo, somadas às práticas tradicionais de corte e queima historicamente ligadas à própria cultura da mandioca em terra firme, representam uma reconfiguração do espaço rural que influencia diretamente o padrão de uso da terra e, consequentemente, as taxas de desmatamento de áreas florestais para exploração agropecuária (CAMELI; SILVA, 2024).

Nesse cenário de exploração florestal, dados de desmatamento do PRODES indicam que o município de Cruzeiro do Sul-AC apresentou variações significativas na área desmatada entre 2008 e 2022, com alternância entre períodos de redução e aumento (INPE, 2022a). Entre 2008 e 2017, as taxas mantiveram flutuações moderadas, com mínimo de 3,43 km² em 2015 e máximo de 22,18 km² em 2010. A partir de 2018, observa-se uma intensificação do desmatamento, com a área desmatada praticamente dobrando em relação ao ano anterior (18,06 km²) e atingindo 54,71 km² em 2022, o maior valor da série histórica (INPE, 2022a). Esse aumento recente está associado principalmente à expansão da pecuária e à abertura de novas frentes agrícolas no município, intensificando a pressão sobre a cobertura florestal nativa e reforçando a necessidade de monitoramento contínuo da biomassa e integridade florestal, assim como os distúrbios incidentes sobre a floresta (GATTI et al., 2021; RODRIGUES, 2024; CAMELI; SILVA, 2024).

2.2 Materiais

Para a realização deste estudo, foram utilizadas diferentes bases de dados geoespaciais com foco no ano de 2014 e 2022. Os dados estão detalhados na Tabela 2.1.

Tabela 2.1 - Base de dados

Fonte de Dados	Ano(s)	Tipo de Dado
DEGRAD (INPE, 2008)	2008 à 2014	Vetorial
TERRACCLASS (INPE, 2022c)	2008 à 2022	Matricial
ESA CCI BIOMAS (SANTORO; CARTUS, 2024)	2015 e 2022	Matricial
PRODES (INPE, 2022a)	2014 e 2022	Matricial
DETER (INPE, 2022b)	2018 à 2022	Vetorial
Limites Municipais (IBGE, 2022a)	2022	Vetorial

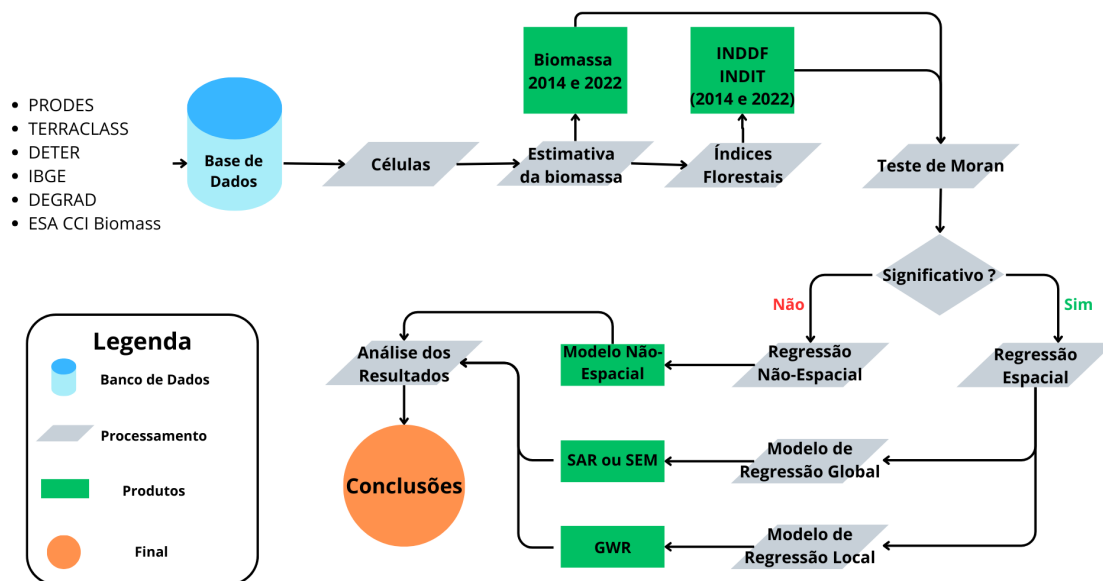
Fonte: Produção do autor (2025).

O Índice de Distúrbio Florestal (INDDF) e o Índice de Integridade Florestal (INDIT) são adaptações dos índices propostos por [Rodrigues et al. \(2025\)](#). O maior detalhamento dos cálculos realizados para a estimativa dos dois índices serão descritos nas Seções 2.3.3 e 2.3.4.

2.3 Métodos

A Figura 2.2 apresenta o fluxograma metodológico utilizado no estudo. O processo inicia-se com a compilação das bases de dados, que são organizadas em células e utilizadas para a estimativa de biomassa e para o cálculo dos índices florestais referentes aos anos de 2014 e 2022. Em seguida, aplica-se o teste de Moran para verificar a presença de autocorrelação espacial. Caso o resultado não seja significativo, procede-se com modelos de regressão não-espacial; caso contrário, adotam-se modelos espaciais. Esses modelos incluem abordagens globais e locais, cujos resultados são posteriormente analisados para compor as conclusões finais do estudo.

Figura 2.2 - Fluxograma metodológico do estudo.



Fonte: Produção do autor (2025).

2.3.1 Definição da Grade Celular

Com a base de dados previamente estruturada, foi gerada uma malha quadriculada sobre os dados geoespaciais obtidos, com o objetivo de uniformizar as unidades de análise espacial. O tamanho de cada célula foi definido de forma empírica, sendo estabelecida uma área de 4 km² (2 km x 2 km) por célula, de modo a permitir a integração entre as diferentes resoluções espaciais dos dados utilizados (CARNEIRO, 2006; CARNEIRO et al., 2013). Além disso, essa malha serviu como unidade básica para a elaboração dos índices florestais e posterior modelagem da biomassa acima do solo ao longo do período analisado.

2.3.2 Estimativa da Biomassa Acima do Solo (AGB)

A estimativa da *AGB* (*Above-Ground Biomass*) para o ano de 2014 foi obtida por meio de um modelo de retroprojeção utilizando dados *ESA CCI BIOMASS* para o ano de 2015, implementado no ambiente estatístico R (SANTORO; CARTUS, 2024; HIJMANS, 2025). Também foram utilizados os dados de desmatamento dos anos de 2014 e 2015 proveniente do programa PRODES (INPE, 2022a).

A estimativa de biomassa foi feita por meio de um algoritmo iterativo que operou pixel a pixel, ajustando os valores de *AGB* de 2015 com base na localização dos polígonos de desmatamento. Para os pixels localizados em áreas desmatadas em 2015, assumiu-se que esses continham biomassa florestal maior no ano de 2014. Dessa forma, seus valores foram reconstituídos a partir do valor máximo observado em uma janela focal de 3x3 no mapa de *AGB* de 2015, representando a condição da floresta adjacente mais densa e menos impactada. Por outro lado, os pixels localizados em áreas desmatadas em 2014 tiveram seus valores ajustados para o mínimo positivo (>0) encontrado na mesma vizinhança, simulando uma condição de biomassa residual, característica de áreas de borda ou transição florestal. Para os pixels observados em áreas fora dos polígonos de desmatamento entre 2014 e 2015, os valores originais de *AGB* de 2015 foram mantidos inalterados.

Posteriormente, já com os valores de *AGB* estimados para o ano de 2014, foi então somados os valores dos pixels contidos dentro de cada uma das células da grade, devido a resolução espacial do dado original (100m x 100m), sendo possível estimar o valor da biomassa para a área celular da grade de análise.

A etapa subsequente consistiu na modelagem da variação da *AGB* na área de estudo, composta por 2.290 células da malha definida. A variável dependente foi estabelecida como a variação total da biomassa (ΔAGB), correspondente ao delta entre o somatório da biomassa nos anos de 2014 e 2022 (2.1). Essa variável permitiu quantificar as mudanças no estoque de biomassa ao longo do período, possibilitando uma análise da dinâmica espacial de perdas e ganhos de biomassa, associada aos processos de desmatamento e regeneração florestal.

$$\Delta AGB = AGB_SUM_2022 - AGB_SUM_2014 \quad (2.1)$$

Em que,

ΔAGB : Variação da Biomassa Acima do Solo (AGB) entre 2014 e 2022;

AGB_SUM_2022 : Biomassa Acima do Solo (AGB) total estimada em 2022 na área de 2 km²;

AGB_SUM_2014 : Biomassa Acima do Solo (AGB) total estimada em 2014 na área de 2 km².

Unidade: Megagramas (Mg).

2.3.3 Índice de Distúrbio Florestal (INDDF)

A partir da base de dados, foram identificadas as classes relacionadas aos distúrbios florestais presentes no Município de Cruzeiro do Sul - AC no ano de 2014 e 2022, sendo elas representadas na Tabela 2.2 (RODRIGUES et al., 2025).

Tabela 2.2 - Classes de estudo

Classes	Base de Dados	Descrição
Desmatamento (DM)	PRODES	Áreas de remoção total da cobertura florestal nativa acumulado.
Floresta Remanescente (FR)	PRODES	Fragmentos de floresta primária preservada.
Vegetação Secundária (VS)	TERRAClass	Áreas em regeneração natural com no mínimo 4 observações.
Degradação Florestal (DG)	DETER	Áreas detectadas como degradação até 4 observações.
Cicatriz de Incêndios (CI)	DETER	Superfícies afetadas por fogo em até 4 observações.

Fonte: Produção do autor (2025).

Para integrar e analisar diferentes informações espaciais, todas as camadas temáticas utilizadas neste estudo foram convertidas para o formato raster. Posteriormente, foi calculada a área de cobertura de cada classe dentro de cada uma das células, o que permitiu estimar a área de floresta original, que representa a área que inicialmente teria cobertura florestal, dada pela equação:

$$F_{\text{orig}} = \text{Área}(\text{DM}) + \text{Área}(\text{FR}) + \text{Área}(\text{VS}) \quad (2.2)$$

Em que,

F_{orig} : Área de floresta original em cada célula;

$\text{Área}(\text{DM})$: Área da classe DM em cada célula;

Área(FR): Área da classe FR em cada célula;

Área(VS): Área da classe VS em cada célula.

Unidade: Metros quadrados (m²).

A elaboração dos indicadores florestais se deu a partir da área ocupada por cada uma das classes dentro de cada célula. Os indicadores utilizados no trabalho estão representados na Tabela 2.3 (RODRIGUES et al., 2025).

Tabela 2.3 - Indicadores utilizados para o cálculo do INDDF

Nome do Indicador	Equação	Unidade
Indicador de Degradação Florestal (IndDG)	$\text{IndDG} = \frac{\text{Área(DG)} + \text{Área(CI)}}{F_{\text{orig}}}$	Adimensional
Indicador de Desmatamento Florestal (IndDM)	$\text{IndDM} = \frac{\text{Área(DM)}}{F_{\text{orig}}}$	Adimensional
Indicador de Regeneração Florestal (IndRG)	$\text{IndRG} = \frac{\text{Área(VS)}}{F_{\text{orig}}}$	Adimensional

Fonte: Produção do autor (2025).

Para a aplicação da técnica AHP (*Analytic Hierarchy Process*), foi construída uma matriz de comparação pareada para avaliar a influência relativa de cada indicador nos distúrbios florestais. A definição dos pesos foi realizada com base na escala proposta por Saaty (2008), que varia de 1 a 9, sendo 1 atribuído quando dois critérios têm igual relevância, e 9 quando um critério é extremamente mais relevante que o outro.

Com base na metodologia elaborada por Rodrigues et al. (2025), definiu-se que o *IndDM* apresenta forte relação com os distúrbios florestais, sendo mais relevante do que o *IndDG*, e levemente mais importante que o *IndRG*. Do mesmo modo, a comparação entre o *IndRG* e o *IndDG* indicou uma importância moderada do primeiro

em relação ao segundo. Considera-se que a vegetação secundária está associada a áreas anteriormente desmatadas, sendo interpretada como um componente de compensação no contexto do Índice de Distúrbio Florestal (*INDDF*).

A aplicação do método AHP resultou na atribuição dos seguintes pesos aos indicadores utilizados, sendo eles: 0,58 para o *IndDM*, 0,30 para o *IndRG* e 0,12 para o *IndDG*. Posteriormente, foi calculado o Índice de Distúrbio Florestal (*INDDF*), descrito matematicamente por:

$$INDDF = (0,58 \times IndDM) + (0,12 \times IndDG) - (0,30 \times IndRG) \quad (2.3)$$

Em que,

INDDF: Índice de Distúrbio Florestal;

IndDM: Resultado do indicador *IndDM*;

IndDG: Resultado do indicador *IndDG*;

IndRG: Resultado do indicador *IndRG*.

Unidade: Adimensional. Na composição do índice desenvolvido, adotou-se a convenção de que o sinal positivo (+) representa a perda de cobertura vegetal, enquanto o sinal negativo (−) indica o ganho de vegetação.

2.3.4 Índice de Integridade Florestal (*INDIT*)

O *INDIT* (Índice de Integridade Florestal) foi aplicado neste estudo com base na metodologia proposta por [Rodrigues et al. \(2025\)](#). O *INDIT* mensura a integridade das manchas florestais remanescentes na paisagem, considerando fatores como área núcleo, fragmentação, conectividade e persistência da cobertura florestal.

O índice é composto por quatro indicadores, cada um representando diferentes dimensões da estrutura da paisagem florestal. A Tabela 2.4 detalha os indicadores utilizados.

Os cálculos dos indicadores *IndAC* e *IndPF* são realizados a partir de F_{orig} , conforme a Equação 2.2. O *IndAC* é determinado pela razão entre a área de floresta núcleo e a área de floresta original, conforme descrito na equação 2.4. A área núcleo é definida

Tabela 2.4 - Indicadores utilizados no cálculo do INDIT

Nome do Indicador	Descrição das Métricas	Unidade
Indicador de Área Core (IndAC)	Proporção da área núcleo da Floresta Remanescente (FR), indicando resiliência estrutural.	Adimensional
Indicador de Persistência Florestal (IndPF)	Proporção da FR que é classificada como área de vegetação secundária com pelo menos 4 observações.	Adimensional
Indicador de Fragmentação Florestal (IndFF)	Grau de fragmentação, calculado pela proporção do número de manchas de FR na paisagem.	Adimensional
Indicador de Conectividade Florestal (IndFC)	Grau de conectividade, calculado pela distância média euclidiana entre as manchas de FR.	Adimensional

Fonte: Produção do autor (2025).

como a porção de floresta nativa remanescente após a aplicação de um buffer interno de 300 m, que considera o efeito de borda sobre o fragmento.

$$\text{IndAC} = \frac{\text{Área de Floresta CORE}}{F_{\text{orig_CORE}}} \quad (2.4)$$

Em que:

Área de Floresta Core: área de floresta nativa do ano analisado subtraída de um buffer interno de 300 m;

F_{orig} : área de floresta original em cada célula subtraída de um buffer interno de 300 m.

Unidade: Adimensional.

O *IndPF* é definido como a proporção da área de vegetação secundária observada em pelo menos quatro mapeamentos consecutivos, em relação à área de floresta original, conforme a Equação 2.5.

$$\text{IndPF} = \frac{\text{Área de Veg. Secundária} \geq 4 \text{ Avistamentos}}{F_{\text{orig}}} \quad (2.5)$$

Em que:

Área de Veg. Secundária ≥ 4 Avistamentos: área de vegetação secundária identificada em no mínimo quatro períodos consecutivos;

F_{orig} : área de floresta original em cada célula.

Unidade: Adimensional.

A atribuição dos pesos dos indicadores foi realizada utilizando a técnica AHP, conforme a escala de comparação pareada proposta por [Saaty \(2008\)](#). Nessa adaptação, considerou-se que o *IndAC* representa o fator de maior relevância para a integridade Florestal, seguido pelo *IndPF*. Por outro lado, *IndFF* e *IndFC* configuram fatores de estresse, com contribuição negativa para o índice.

A aplicação do método AHP resultou na definição dos seguintes pesos: 0,55 para o *IndAC* e 0,15 para cada um dos indicadores *IndPF*, *IndFC* e *IndFF*. Assim, o *INDIT* é obtido por meio de uma equação ponderada, conforme a Equação 2.6.

$$\text{INDIT} = (0,55 \times \text{IndAC}) + (0,15 \times \text{IndPF}) - (0,15 \times \text{IndFC}) - (0,15 \times \text{IndFF}) \quad (2.6)$$

Em que:

INDIT: Índice de integridade Florestal;

IndAC: Indicador de Área Core;

IndPF: Indicador de Persistência Florestal;

IndFC: Indicador de Conectividade Florestal;

IndFF: Indicador de Fragmentação Florestal.

Unidade: Adimensional.

Os sinais positivos (+) indicam fatores que promovem a integridade estrutural, enquanto os sinais negativos (−) correspondem a fatores que a comprometem.

2.3.5 Diagnóstico de Autocorrelação Espacial

A segunda etapa metodológica compreendeu o diagnóstico da estrutura espacial dos dados para avaliar a presença de autocorrelação espacial, um fenômeno que viola a premissa de independência das observações exigida pelos modelos de Mínimos Quadrados Ordinários (OLS) (BAILEY; GATRELL, 1995; BRUSDON et al., 1996). A autocorrelação espacial, onde valores de locais vizinhos apresentam-se sistematicamente relacionados, foi quantificada para as variáveis de Variação da Biomassa Acima do Solo (ΔAGB), Variação do Índice de Integridade Florestal ($\Delta INDIT$) e Variação do Índice de Distúrbio Florestal ($\Delta INDDF$) por meio do índice I de Moran Global, descrita matematicamente na equação 2.7 (MORAN, 1948).

$$I = \frac{n \sum_{i=1}^n \sum_{j=1}^n w_{ij} (X_i - \bar{X})(X_j - \bar{X})}{\left(\sum_{i=1}^n \sum_{j=1}^n w_{ij} \right) \sum_{i=1}^n (X_i - \bar{X})^2} \quad (2.7)$$

Em que:

I : Índice de Moran Global;

n : Número total de unidades espaciais;

X_i, X_j : Valores da variável observada nos locais i e j ;

\bar{X} : Média aritmética global da variável na área de estudo;

w_{ij} : Elementos da matriz de pesos espaciais;

$\sum \sum w_{ij}$: Somatório de todos os pesos da matriz de vizinhança.

Unidade: Adimensional.

A construção da matriz W baseou-se no critério de contiguidade do tipo *Rainha* (*Queen's contiguity*), no qual polígonos são definidos como vizinhos ao compartilhar qualquer borda ou vértice (ANSELIN, 1988b). Subsequentemente, a matriz de contiguidade foi normalizada por linha, transformando W em uma matriz de pesos relativos para garantir a comparabilidade da influência espacial entre as unidades. Nesse modelo, se um polígono possui n vizinhos, cada um recebe um peso equivalente a $1/n$, o que evita que áreas com elevada conectividade distorçam a média

global da amostra (ANSELIN, 1988b; CHEN, 2013). O valor do *I de Moran* resultante é, portanto, interpretável como um autovalor (λ) de uma matriz de correlação espacial generalizada, onde valores positivos indicam agrupamentos, valores negativos indicam dispersão, e valores = 0 indicam uma distribuição espacial aleatória dos dados (MORAN, 1948; CHEN, 2013).

2.3.6 Modelagem Espacial Global (SAR/SEM)

A constatação da autocorrelação espacial dos dados analisados (Seção 2.3.5) interfere em inferências estatísticas dos OLS, uma vez que os erros padrão dos coeficientes tornam-se enviesados, levando a testes instáveis (ANSELIN, 1988b; BAILEY; GATRELL, 1995). A etapa metodológica subsequente foi determinar a arquitetura de modelo espacial global mais apropriada para corrigir essa dependência. Para guiar esta seleção, foi primeiramente ajustado um modelo OLS de base unicamente como um passo necessário para gerar os resíduos. A estrutura de dependência espacial nesses resíduos foi então avaliada através dos testes de Multiplicador de Lagrange (LM), que avaliam duas hipóteses distintas: a dependência de Lag Espacial (LM-Lag), onde a variável resposta é influenciada pelos seus vizinhos, e a dependência de Erro Espacial (LM-Error), onde os resíduos são espacialmente autocorrelacionados (ANSELIN, 1988a).

Contudo, dado que os testes LM simples são suscetíveis a indicar uma dependência espúria na presença de outra forma de autocorrelação, a análise priorizou o uso dos testes robustos (ANSELIN et al., 1996). A comparação das estatísticas e p-valores destes dois testes robustos permitiu determinar a estrutura de dependência mais provável, direcionando a seleção entre duas especificações de modelo mutuamente exclusivas: o Modelo de Lag Espacial (SAR)¹, que incorpora a dependência substantiva através do parâmetro *Rho* (ρ); ou o Modelo de Erro Espacial (SEM)², que captura a dependência de perturbação através do parâmetro *Lambda* (λ) (ANSELIN, 1988b).

Uma vez definida esta arquitetura de modelo base, procedeu-se à calibração de um conjunto de modelos concorrentes, utilizando as diferentes fórmulas candidatas identificadas. A seleção da especificação final ótima, dentre os modelos concorrentes, foi baseada em métricas de ajuste e parcimônia.

O Critério de Informação de Akaike (AIC) foi usado para comparar o ajuste rela-

¹*Spatial Autoregressive Model.*

²*Spatial Error Model.*

tivo, onde valores menores indicam um melhor equilíbrio entre ajuste e parcimônia (AKAIKE, 1973; ANSELIN, 1988b; PINHEIRO et al., 2019). Juntamente à seleção, foram gerados diagnósticos para todos os modelos globais a fim de verificar as premissas estatísticas, aplicando-se o teste de Shapiro-Wilk para atestar a normalidade dos resíduos, o teste de Breusch-Pagan para testar a heterocedasticidade e o índice I de Moran para avaliar a autocorrelação espacial dos resíduos (MORAN, 1948; SHAPIRO; WILK, 1965; BREUSCH; PAGAN, 1979).

2.3.7 Modelagem Espacial Local (GWR)

A última etapa investigou a hipótese de não-estacionariedade dos processos³. Esta hipótese parte do pressuposto de que os modelos espaciais globais, embora corrijam a autocorrelação, ainda impõem a restrição de que a relação entre as variáveis é constante em toda a área de estudo (BRUSDON et al., 1996; FOTHERINGHAM et al., 2002). Para testar esta hipótese e permitir que os coeficientes variem localmente, foi empregada a Regressão Geograficamente Ponderada (GWR) (BRUSDON et al., 1996; FOTHERINGHAM et al., 2002). A GWR calibra os valores do modelo de regressão para cada unidade de observação, ponderando os vizinhos com base na sua proximidade (BRUSDON et al., 1996; FOTHERINGHAM et al., 2002; CARVALHO et al., 2006).

Com base nos modelos aplicados na modelagem global (Seção 2.3.6), foi selecionado o melhor modelo global e ajustado um modelo GWR. Dito isso, o modelo foi calibrado com um *bandwidth* adaptativo, que se adapta dinamicamente de acordo com a densidade dos vizinhos locais (FOTHERINGHAM et al., 2002; GUO et al., 2008). Diferentemente do *bandwidth* fixo, o adaptativo é definido com base em um número constante de vizinhos mais próximos, permitindo que cada regressão local seja ajustada a partir de uma subamostra de tamanho variável conforme a dispersão geográfica dos dados (FOTHERINGHAM et al., 2002; CARVALHO et al., 2006; GUO et al., 2008). A calibração do modelo baseou-se na busca pelo *bandwidth* ótimo através da minimização do Critério de Informação de Akaike corrigido, testando sucessivos raios de vizinhança até encontrar o menor valor de AICc (GUO et al., 2008).

Adicionalmente, utilizou-se a função de decaimento *bisquare*, que governa a atribuição de pesos às observações vizinhas (GUO et al., 2008). Esta função garante que o peso decresça suavemente com a distância em relação ao ponto de regressão, assegurando que observações fora do limite estabelecido pelo *bandwidth* não exerçam

³Não-estacionariedade refere-se a relações que mudam no espaço, ou seja, os coeficientes do modelo não são constantes em toda a área de estudo.

influência no ajuste local (GUO et al., 2008).

A avaliação do modelo GWR baseou-se na comparação direta de seus valores do Critério de Informação de Akaike Corrigido (AICc) (FOTHERINGHAM et al., 2002; COMBER et al., 2020). Posteriormente, foram testadas a suposição de normalidade dos erros, por meio do teste de Shapiro-Wilk (SHAPIRO; WILK, 1965). Por fim, para confirmar a eficácia do modelo em controlar a dependência espacial, aplicou-se o Índice de Moran sobre os resíduos, testando a hipótese nula de aleatoriedade espacial (MORAN, 1948).

3 ANÁLISE E RESULTADOS

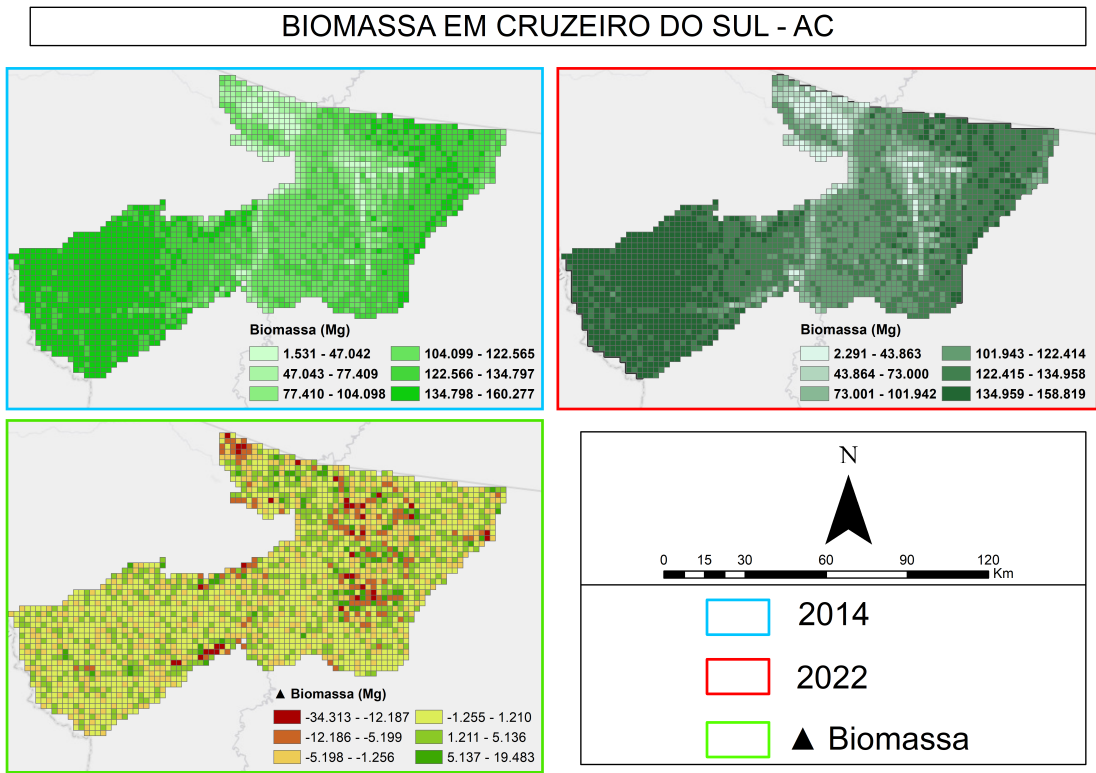
Com base na metodologia descrita no capítulo 2, o capítulo a seguir apresenta e discute os resultados obtidos a partir dos processamentos realizados.

3.1 Análise das Variáveis florestais

3.1.1 Variação da Biomassa acima do solo (ABG)

A Figura 3.1 apresenta a distribuição espacial da Biomassa Acima do Solo (AGB), em Megagramas (Mg), para os anos de 2014 e 2022, assim como a variação (Δ) ocorrida entre os dois anos citados.

Figura 3.1 - Distribuição da Biomassa (AGB) em Cruzeiro do Sul (2014-2022)



Fonte: Produção do autor (2025).

No bloco com contorno azul observa-se o cenário de 2014, no qual se destaca a predominância de células com valores elevados de biomassa distribuídas ao longo da área analisada. Já o bloco com contorno vermelho corresponde ao ano de 2022 e tam-

bém apresenta uma maior concentração de células com altos estoques de biomassa, embora com diferenças perceptíveis em algumas regiões.

Na comparação entre 2014 e 2022, nota-se uma redução nos estoques de biomassa em áreas específicas do município. As regiões próximas ao Projeto de Assentamento Santa Luzia e à sede municipal exibem células em tonalidades mais claras no ano de 2022, indicando uma diminuição dos valores.

A variação espacial da biomassa é apresentada no bloco com contorno verde. As células com valores negativos representam os locais onde ocorreu perda de biomassa entre os anos analisados. Em contrapartida, observa-se a presença de células com valores positivos distribuídas de forma mais dispersa, o que indica ganhos pontuais de biomassa. Também se identificam áreas com valores próximos de zero, que sugerem estabilidade nos estoques ao longo do município.

Para complementar a análise, as estatísticas descritivas referentes aos valores de biomassa de 2014 e 2022, bem como da variação entre esses anos, foram extraídas e estão apresentadas na Tabela 3.1.

Tabela 3.1 - Estatísticas descritivas da Biomassa (AGB) por célula (2km x 2km).

Estatística	AGB 2014 (Mg)	AGB 2022 (Mg)	Variação (Δ AGB) (Mg)
Mínimo	2.291,00	1.531,00	-34.313,00
Máximo	158.819,00	160.277,00	19.483,00
Média	119.908,00	120.277,40	-369,41
Mediana	128.248,00	127.906,50	9,00
Moda	135.882,90	135.293,90	239,58

Fonte: Produção do autor (2025).

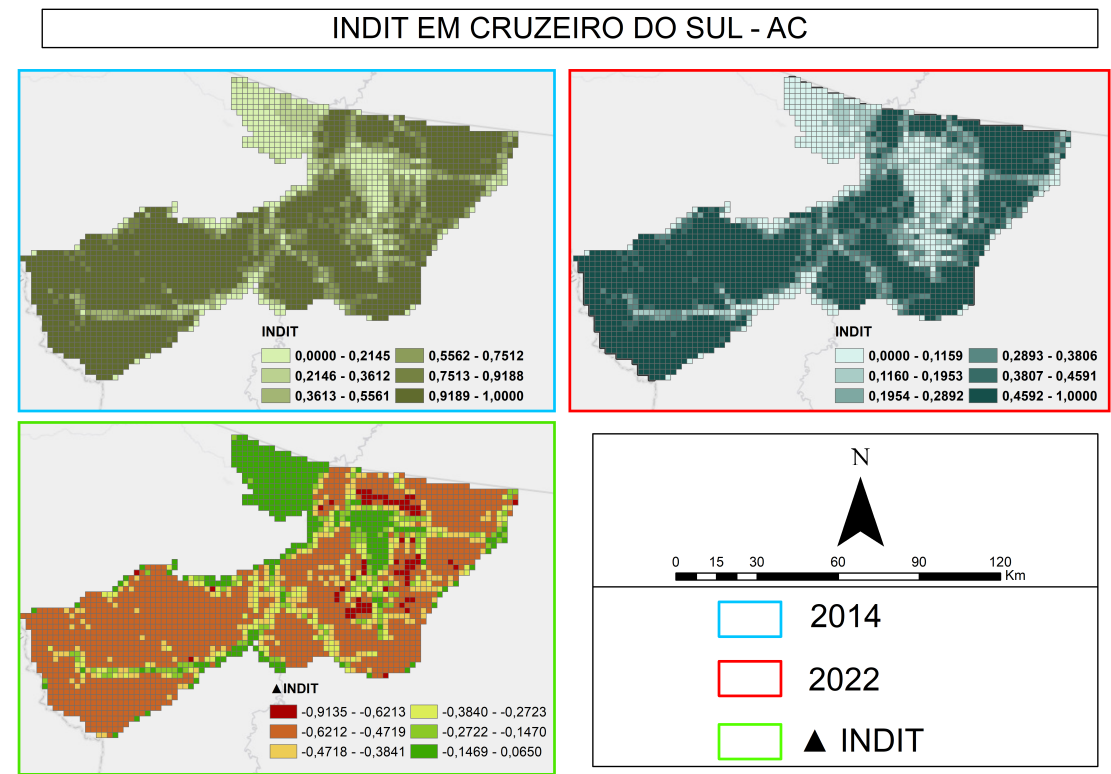
A Tabela 3.1 mostra que, embora os valores médios de biomassa em 2014 e 2022 sejam próximos, a coluna referente à Variação (Δ AGB) apresenta uma média negativa de -369,41 Mg. Esse resultado confirma que, no total, o município registrou perda de biomassa no período analisado, o que é reforçado pelo valor mínimo observado, de -34.313,00 Mg. Por outro lado, a mediana e a moda apresentam valores positivos, 9,00 Mg e 239,58 Mg, respectivamente. Esses resultados indicam que, apesar de muitas células terem permanecido estáveis ou apresentado pequenos ganhos, as perdas concentradas em determinadas áreas exerceram maior influência no comportamento

geral.

3.1.2 Variação dos Índice de Integridade Florestal

A Figura 3.4 apresenta a distribuição espacial do Índice de Distúrbio e Integridade Florestal (INDIT) para os anos de 2014 e 2022, bem como a variação entre esses períodos. No mapa de 2014, representado pelo bloco com contorno azul, observa-se uma predominância de valores intermediários do índice, distribuídos de forma relativamente homogênea ao longo do município. No mapa de 2022, destacado pelo contorno vermelho, nota-se um padrão semelhante, embora algumas áreas apresentem valores mais baixo, indicando menor grau de integridade florestal em comparação ao período anterior.

Figura 3.2 - Distribuição do Índice de Integridade florestal (INDIT) em Cruzeiro do Sul (2014-2022)



Fonte: Produção do autor (2025).

A variação espacial exibida no mapa destacado pelo contorno verde reforça essa ten-

dência. As células com valores negativos aparecem de forma concentrada e abrangente, indicando redução expressiva da integridade florestal em várias porções do município. Em contraste, as células com valores positivos são pontuais e pouco numerosas, o que demonstra que poucos trechos apresentaram algum grau de recuperação ou melhora. Dessa forma, a análise visual sugere um cenário de declínio estrutural da vegetação entre 2014 e 2022.

A Tabela 3.2 complementa a interpretação visual ao apresentar as estatísticas descritivas do índice nos dois anos e da variação entre eles. Os valores mínimos e máximos permanecem iguais em 2014 e 2022, o que indica que as condições extremas de integridade se mantiveram. Porém, a média apresenta uma redução acentuada, passando de 0,783 para 0,367, o que confirma uma queda da integridade florestal em grande parte do município. Do mesmo modo, a mediana e a moda também diminuem, mostrando que a maioria das células experimentou uma redução de integridade. Esses valores resultaram em uma variação média negativa de -0,416, demonstrando que o declínio ocorreu em uma generalização das células.

Tabela 3.2 - Estatísticas descritivas do Índice de Integridade Florestal (INDIT).

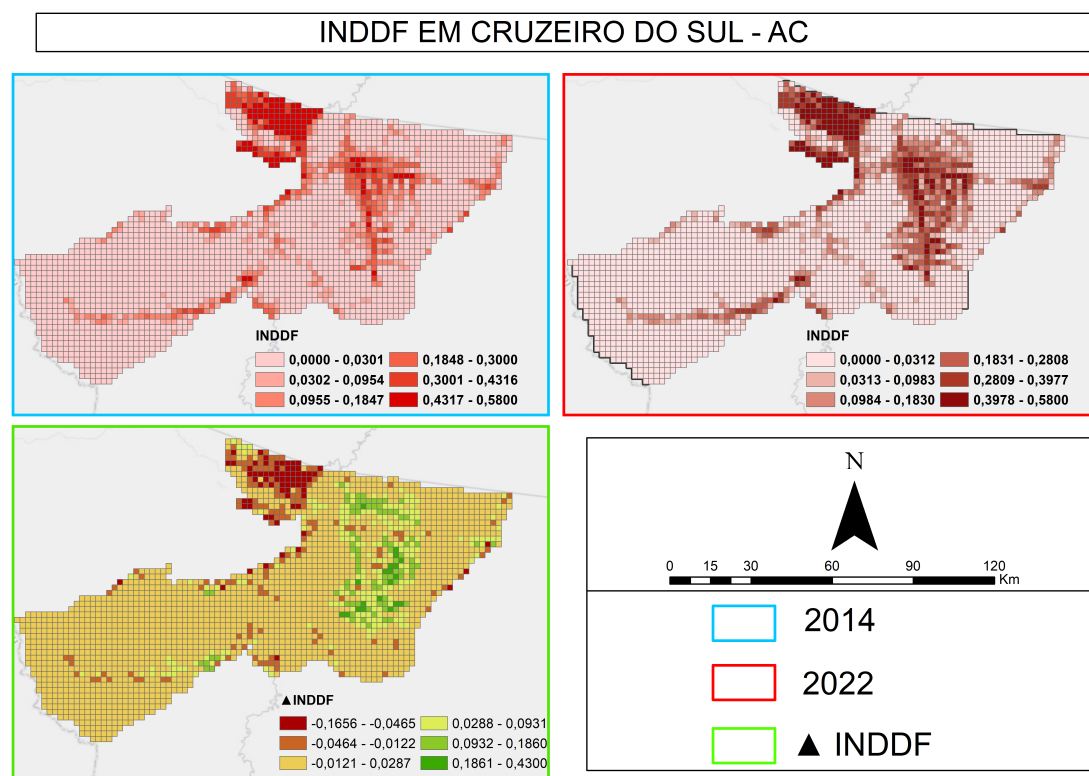
Estatística	INDIT 2014	INDIT 2022	Δ INDIT
Mínimo	0,000	0,000	-0,913
Máximo	1,000	1,000	0,065
Média	0,783	0,367	-0,416
Mediana	1,000	0,480	-0,505
Moda	0,996	0,492	-0,504

Fonte: Produção do autor (2025).

3.1.3 Variação dos Índice de Distúrbio Florestal

A Figura 3.3 sintetiza o comportamento espacial do Índice de Distúrbio Florestal (INDDF) nos anos de 2014 e 2022, além da diferença registrada entre eles. No mapa de 2014, delimitado em azul, é notável um predomínio de áreas com baixos valores do índice, o que revela um cenário inicial de distúrbio pouco expressivo no município. Porém, observa-se a presença de algumas zonas de maior intensidade, especialmente na porção norte.

Figura 3.3 - Distribuição do Índice de Distúrbio florestal (INDDF) em Cruzeiro do Sul (2014-2022)



Fonte: Produção do autor (2025).

No mapa de 2022, destacado em vermelho, observa-se uma mudança mais expressiva na configuração espacial do distúrbio. Regiões que antes apresentavam valores menores passam a registrar concentrações mais marcantes, especialmente no próximo ao projeto de assentamento Santa Luzia. Esse comportamento sugere o avanço de atividades humanas capazes de provocar alterações nos níveis de distúrbios captados pelo INDDF.

A variação entre os anos representada pelo mapa com contorno verde reforça essa dinâmica. As células com incremento positivo do índice concentram-se justamente nas áreas previamente afetadas, indicando que o distúrbio não apenas persistiu, mas também se intensificou. Já as células com valores negativos, que indicam redução dos valores do índice, são menos recorrentes e esparsas.

A Tabela 3.3 aprofunda essa interpretação ao apresentar as estatísticas descritivas

do índice nos dois anos. O aumento da média, de 0,063 em 2014 para 0,073 em 2022, revela uma elevação gradual, ainda que moderada, do nível geral de distúrbio. A manutenção da mediana e da moda em zero confirma que a maior parte das células continua apresentando pouca alteração, mas a variação média positiva de 0,009 demonstra que, no conjunto, houve intensificação do distúrbio, coerente com os padrões espaciais identificados nos mapas.

Tabela 3.3 - Estatísticas descritivas do Índice de Distúrbio Florestal (INDDF).

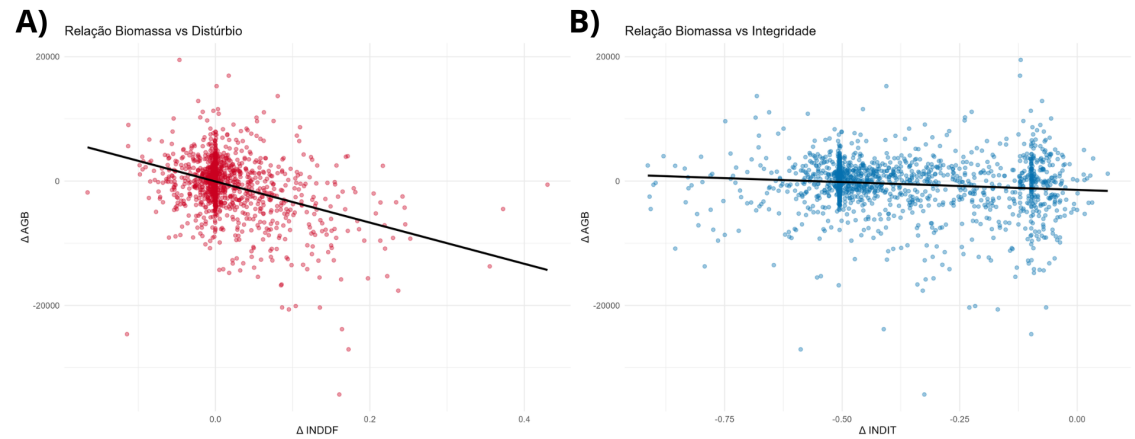
Estatística	INDDF 2014	INDDF 2022	Δ INDDF
Mínimo	0,000	0,000	-0,166
Máximo	0,580	0,580	0,430
Média	0,063	0,073	0,009
Mediana	0,000	0,000	0,000
Moda	0,001	0,001	0,000

Fonte: Produção do autor (2025).

3.1.4 Relação das Variáveis Florestais

A Figura 3.4 apresenta a análise de dispersão e a tendência linear entre a variação da biomassa acima do solo (Δ AGB) e a variação dos indicadores florestais para as 2290 células amostrados. No gráfico A, observa-se a relação entre Δ AGB e o Índice de Distúrbio (Δ INDDF), revelando uma correlação negativa onde o incremento do distúrbio está associado à perda de biomassa. No gráfico B, a relação com o Índice de Integridade (Δ INDIT) quase não se nota inclinação na linha de tendência global, sugerindo uma baixa relação entre os valores das variáveis.

Figura 3.4 - Comparação dos valores das variáveis florestais: (A) Relação Biomassa vs Distúrbio e (B) Relação Biomassa vs Integridade



Fonte: Produção do autor (2025).

3.2 Diagnóstico de Autocorrelação Espacial

Com base na metodologia descrita na Seção 2.3.5, o primeiro passo da análise estatística foi averiguar a estrutura de dependência espacial das variáveis. Os resultados do teste, apresentados na Tabela 3.4, rejeitam a hipótese nula de aleatoriedade espacial para todas as três variáveis.

Tabela 3.4 - Resultados do teste *I de Moran Global* para as variáveis do estudo.

Variável	<i>I de Moran</i>	Desvio Padrão	p-valor
ΔAGB	0,0993	9,2478	< 2.2e-16
$\Delta INDIT$	0,6849	63,4010	< 2.2e-16
$\Delta INDDF$	0,5542	51,4910	< 2.2e-16

Fonte: Produção do autor (2025).

Todas as variáveis apresentaram autocorrelação espacial positiva e estatisticamente

significativa ($p < 0,001$). Isso indica que os valores não estão distribuídos aleatoriamente no espaço; ao contrário, eles demonstram um padrão de agrupamento (MORAN, 1948).

As variáveis Δ INDIT e Δ INDDF apresentaram os maiores valores de Moran ($I = 0,685$ e $I = 0,554$, respectivamente), indicando um forte agrupamento espacial. Isso demonstra que os processos de perda de integridade e de aumento de distúrbio ocorrem de forma concentrada, formando agrupamentos na paisagem, o que é coerente com a natureza de fenômenos como o desmatamento, que se expande a partir de focos consolidados (ESCADA et al., 2023).

Do mesmo modo, a Variação da Biomassa (Δ AGB) também apresentou autocorrelação positiva significativa ($I = 0,099$), embora com magnitude inferior à dos índices. Esse valor baixo do *I de Moran*, pode estar relacionado com a agregação dos dados de uma resolução espacial mais refinada, originalmente 100 m x 100 m, para uma resolução espacial mais grosseira, sendo adequada a célula de 2km x 2km. Esse processo de transformação espacial pode ter suavizado as evidências de agrupamentos espaciais, o que se refletiu num menor valor do *I de Moran*, ainda que significativo (OPENSHAW, 1984; OLIVER, 2001).

3.3 Modelo Espacial Global

3.3.1 Definição do Modelo Espacial Global

Após a constatação da autocorrelação espacial apresentada na Seção 3.2, a etapa seguinte consistiu em definir a arquitetura de modelo espacial global mais adequada para corrigir essa dependência, conforme descrito na metodologia da Seção 2.3.6.

Primeiramente, foi ajustado um modelo OLS de base utilizando a fórmula de interação linear entre os índices, que apresentou um Pseudo R^2 de 0,1986. Sobre os resíduos desse modelo, aplicaram-se os testes de Multiplicador de Lagrange (LM) robustos para identificar a natureza da dependência espacial.

Os resultados dos testes de diagnóstico indicaram a aplicabilidade de ambos os modelos espaciais, SAR ou SEM. Contudo, a estatística do LM de Erro Robusto ($adjRSerr = 183.02$, $p < 2.2e - 16$) foi superior à do LM de Lag Robusto ($adjRSlag = 111.43$, $p < 2.2e - 16$).

Ao comparar as métricas de desempenho, observou-se que o modelo SEM apresentou um AIC de 4.351.311, valor inferior aos 4.358.975 obtidos pelo modelo SAR,

indicando um melhor ajuste relativo e maior parcimônia. Adicionalmente, o modelo SEM demonstrou um maior poder explicativo, com um R^2 Ajustado de 0,2449 frente aos 0,204 do modelo SAR.

Assim, utilizando os valores obtidos como critério de decisão, o modelo SEM foi selecionado como a estrutura mais apropriada para os dados, sugerindo que a autocorrelação está associada ao erros espacialmente correlacionadas, e não a influência da variável dependente exercida sobre seus vizinhos (ANSELIN, 1988b; ANSELIN et al., 1996). A etapa seguinte consistiu em identificar a fórmula com maior poder explicativo, utilizando o SEM como base para a calibração das diferentes especificações testadas.

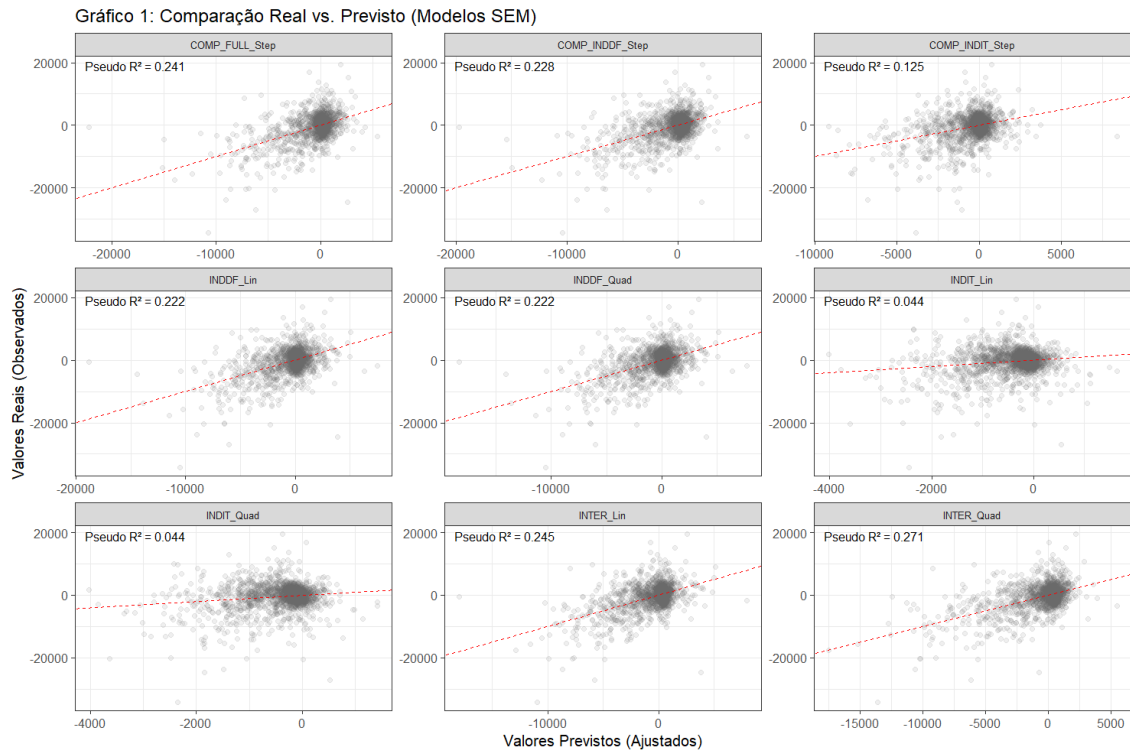
3.3.2 Desempenho das Diferentes Abordagens para o Modelo Espacial Global

A Tabela A.1 do documento Anexo A detalha as equações das hipóteses concorrentes para a variação da biomassa em função dos índices florestais. Nesse contexto, os modelos *INDIT_Lin* e *INDDF_Lin* testam relações lineares simples entre cada índice e a variável resposta. As versões *INDIT_Quad* e *INDDF_Quad* exploram uma possível não linearidade, avaliando se o comportamento dos índices segue uma tendência polinomial de segunda ordem. Os modelos de interação investigam se o efeito de um índice depende do nível do outro (MONTGOMERY; RUNGER, 1994). A fórmula *INTER_Lin* analisa essa interação de forma linear, enquanto *INTER_Quad* considera uma interação não linear (NETER et al., 1996). Por fim, os modelos baseados em componentes decompõem os índices nos indicadores internos; aqueles com sufixo *_Step* foram obtidos por meio de um procedimento *stepwise*, utilizado para reduzir a autocorrelação residual ao selecionar apenas os componentes que contribuíram significativamente para o ajuste do modelo (EFROYMSON, 1960). Assim, *COMP_INDIT_Step* e *COMP_INDDF_Step* avaliam o efeito aditivo dos componentes mais influentes de cada índice, e o modelo *COMP_FULL_Step* combina os indicadores com menor correlação dos dois índices em uma estrutura aditiva única (MONTGOMERY; RUNGER, 1994).

A Figura 3.5 apresenta uma comparação visual do desempenho de todos os nove modelos. Cada painel é um gráfico de dispersão que compara os valores reais da Variação da Biomassa no eixo Y com os valores previstos pelo respectivo modelo no eixo X. A linha tracejada vermelha em cada gráfico representa a linha 1:1, onde um modelo ideal teria todos os pontos alinhados (CHATFIELD; COLLINS, 1986; SINGER et al., 2017). A métrica do Pseudo R^2 é exibida em cada painel, quantificando

o poder explicativo (ANSELIN, 1988b).

Figura 3.5 - Comparação Real vs. Previsto para os modelos SEM.



Fonte: Produção do autor (2025).

Os resultados da Figura 3.5 e os dados apresentados na Tabela A.2, do documento Anexo A, evidenciam que os modelos com os menores valores de AIC são também aqueles que exibem os maiores valores de Pseudo R^2 . Entre eles, o modelo *INTER_Quad* destaca-se como o de melhor desempenho, alcançando o menor critério de informação ($AIC = 43453,25$) e o maior poder explicativo, com um Pseudo R^2 de 0,271. Além disso, os modelos *INTER_Lin* ($AIC = 43513,11$; $R^2 = 0,245$) e *COMP_FULL_Step* ($AIC = 43527,68$; $R^2 = 0,241$) mostraram bons resultados em comparação aos outros modelos testados, caracterizados por nuvens de pontos mais concentradas e próximas da linha 1:1 nos gráficos comparativos (CHATFIELD; COLLINS, 1986).

Estes resultados sugerem que os modelos que incluem a interação entre a variação dos índices (*INTER_Quad* e *INTER_Lin*) obtiveram um ajuste superior aos modelos

que tratam esses fatores de forma independente (BURNHAM; ANDERSON, 2002; CRUZ, 2020). Outrossim, o melhor desempenho do *INTER_Quad* em relação ao *INTER_Lin* indica que a relação entre os índices e a variação da biomassa apresenta comportamento não linear (MONTGOMERY; RUNGER, 1994; PINHEIRO et al., 2019).

Adicionalmente, observa-se que os modelos baseados exclusivamente no Δ INDDF apresentam um ajuste superior aos modelos fundamentados apenas no Δ INDIT, evidenciando diferenças na contribuição explicativa das variáveis dentro de um conjunto multivariado (CHATFIELD; COLLINS, 1986; BURNHAM; ANDERSON, 2002).

3.3.3 Análise Estatística dos Modelos Globais

A adequabilidade dos modelos SEM ajustados foi avaliada por meio de diagnósticos de normalidade, homocedasticidade e independência espacial dos resíduos (MORAN, 1948; SHAPIRO; WILK, 1965; BREUSCH; PAGAN, 1979). A Tabela A.3, no documento Anexo A, apresenta o sumário dos diagnósticos estatísticos para os modelos SEM avaliados.

O teste de Moran's I aplicado aos resíduos dos modelos SEM demonstrou que o ajuste espacial foi capaz de tratar a autocorrelação espacial dos modelos em todos os cenários. Para todos os modelos testados, a hipótese nula de aleatoriedade espacial não pôde ser rejeitada ($p > 0,05$). Isso indica que a estrutura de dependência espacial foi efetivamente capturada e modelada pelo termo de erro, resultando em resíduos espacialmente independentes (MORAN, 1948; CHEN, 2021).

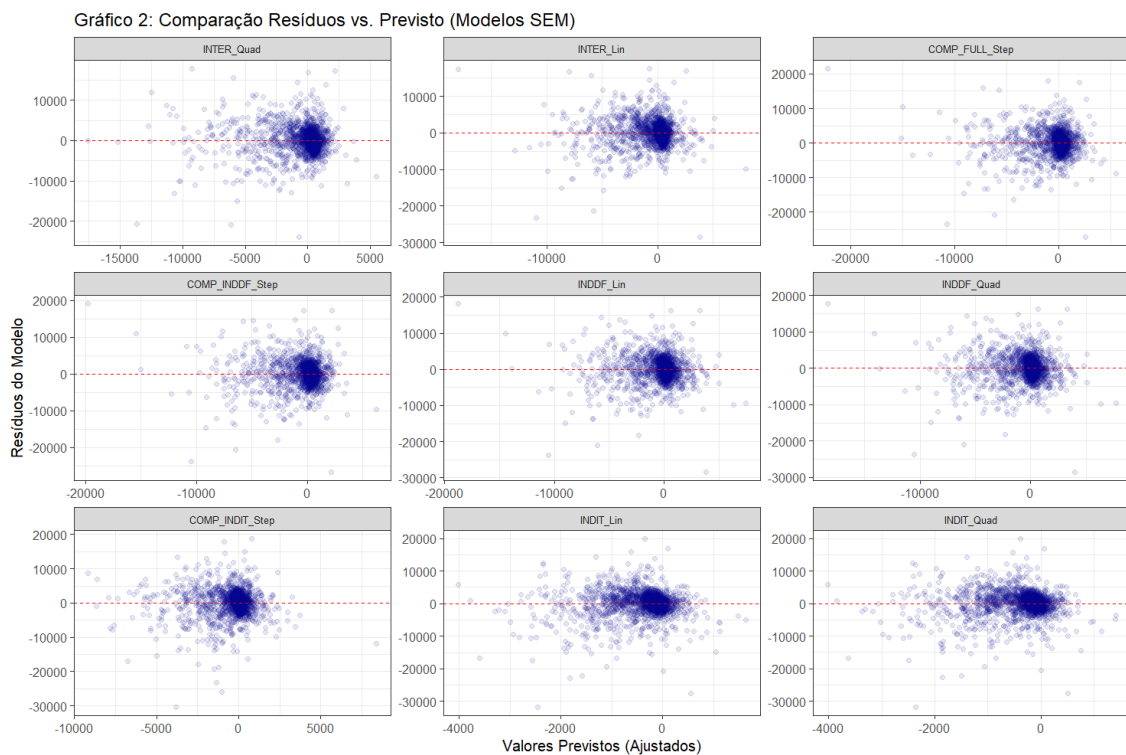
Em relação à distribuição dos erros, o teste de Shapiro-Wilk indicou a rejeição da hipótese de normalidade para todos os modelos, resultado esse podendo estar relacionado ao grande tamanho amostral, o que torna o teste sensível a pequenos desvios da normalidade (TORMAN et al., 2012; BOEDEC, 2016; MIOT, 2017). Da mesma forma, o teste de Breusch-Pagan apontou a presença de heterocedasticidade significativa em todos os ajustes ($p < 0,05$), sugerindo que a variância dos erros não é constante ao longo da área de estudo (BREUSCH; PAGAN, 1979).

3.3.4 Análise de Resíduos para a Modelagem Espacial Global

A Figura 3.6 apresenta a análise de diagnóstico dos resíduos para os nove modelos SEM. O gráfico relaciona os resíduos no eixo Y com os valores previstos no eixo X. Em condições ideais, espera-se que um modelo bem ajustado produza uma distribuição aleatória e homogênea de pontos, sem tendência sistemática ao longo do

eixo dos valores previstos, característica associada à ausência de padrões estruturados nos resíduos (SINGER et al., 2017). Além disso, essa nuvem deve se manter concentrada em torno da linha zero, indicada em vermelho, o que caracteriza homocedasticidade e ausência de estrutura residual, aspectos essenciais para validação de modelos lineares e mistos (NOBRE; SINGER, 2007). Esse comportamento reforça que o modelo não esteja omitindo variáveis relevantes nem capturando relações inadequadas entre os processos representados pelos índices florestais e a variação da biomassa, reforçando a importância de diagnósticos residuais na avaliação de desempenho estatístico (CRUZ, 2020).

Figura 3.6 - Comparação Resíduos vs. Previsto.



Fonte: Produção do autor (2025).

A análise dos gráficos de dispersão revela que os modelos de melhor desempenho, especialmente *INTER_Quad*, *INTER_Lin* e *COMP_FULL_Step*, exibem uma dispersão residual mais homogênea e concentrada em torno da linha zero. Esse padrão sugere um menor viés estrutural e maior adequação da formulação, indicando que a inclusão das interações entre integridade e distúrbio produz um ajuste estatística-

mente mais consistente (NOBRE; SINGER, 2007).

Assim, os valores de AIC e pseudo- R^2 , juntamente ao diagnóstico residual confirmam o *INTER_Quad* como o modelo global que melhor se ajustou, dentre os modelos estudados. Na etapa seguinte, conforme a metodologia apresentada na Seção 2.3.7, será investigado se um modelo local, como a modelagem GWR, é capaz de capturar os efeitos da não-estacionariedade espacial e ampliar a compreensão sobre a distribuição dos coeficientes ao longo do território, aprofundando a análise dos padrões identificados nos modelos globais.

3.4 Modelagem Local Através de GWR

3.4.1 Modelo Local

Conforme apresentado na Seção 3.3, o modelo *INTER_Quad* obteve o melhor desempenho entre as formulações globais avaliadas. Com base nesse resultado, procedeu-se à calibração do modelo GWR correspondente, com o objetivo de investigar possíveis padrões de não-estacionariedade espacial nas relações entre a variação da biomassa e os índices florestais.

O modelo *GWR INTER_Quad* apresentou desempenho superior na representação da relação entre integridade, distúrbio e variação da biomassa, evidenciando que os coeficientes associados à interação polinomial variam espacialmente ao longo do território. Essa flexibilidade permitiu capturar padrões locais não identificados no modelo global SEM, cujo valor de Pseudo R^2 foi de 0,271, enquanto o *GWR INTER_Quad* alcançou um Pseudo R^2 de 0,422. Embora essa diferença indique aumento no poder explicativo, sua interpretação requer cautela, uma vez que modelos GWR tendem a inflar medidas de ajuste devido à variação espacial dos coeficientes, o que nem sempre implica melhoria substantiva nos processos subjacentes (FOTHERINGHAM et al., 2002; GUO et al., 2008).

O critério de informação AICc também reforça a adequação estatística do modelo espacial, com o *GWR INTER_Quad* apresentando valor igual a 43113,28, inferior ao registrado pelo modelo global SEM (AIC = 43453,25). A redução do AICc indica maior adequação do modelo aos dados observados, sugerindo que a interação polinomial entre integridade e distúrbio, quando estimada localmente, proporciona um ajuste mais consistente da variabilidade espacial da biomassa (HURVICH; TSAI, 1989). Além disso, o *bandwidth* convergiu para uma vizinhança composta por 116 unidades espaciais, indicando que a relação entre a variação dos índices florestais e a

variação da biomassa opera em escala local relativamente fina, quando considerada as 2290 unidades presentes no mapa (LU et al., 2018).

A Tabela 3.5 resume os resultados dos teste estatísticos aplicados ao modelo. Nota-se que, apesar da ausência de normalidade nos resíduos, o pressuposto de independência espacial foi plenamente atendido pelo modelo GWR ($p > 0.05$ no teste de Moran), demonstrando que a estrutura de variabilidade espacial da biomassa foi adequadamente modelada pelas variáveis explicativas e seus componentes locais.

Tabela 3.5 - Resultados dos resíduos do modelo GWR (INTER_Quad).

Teste Estatístico	Estatística	p -valor	Conclusão
Normalidade (Shapiro-Wilk)	$W = 0.9396$	$< 0.001^*$	Rejeita H_0
Autocorrelação (I de Moran)	$I = -0.0011$	0.9502	Aceita H_0

* Significativo ao nível de 5%.

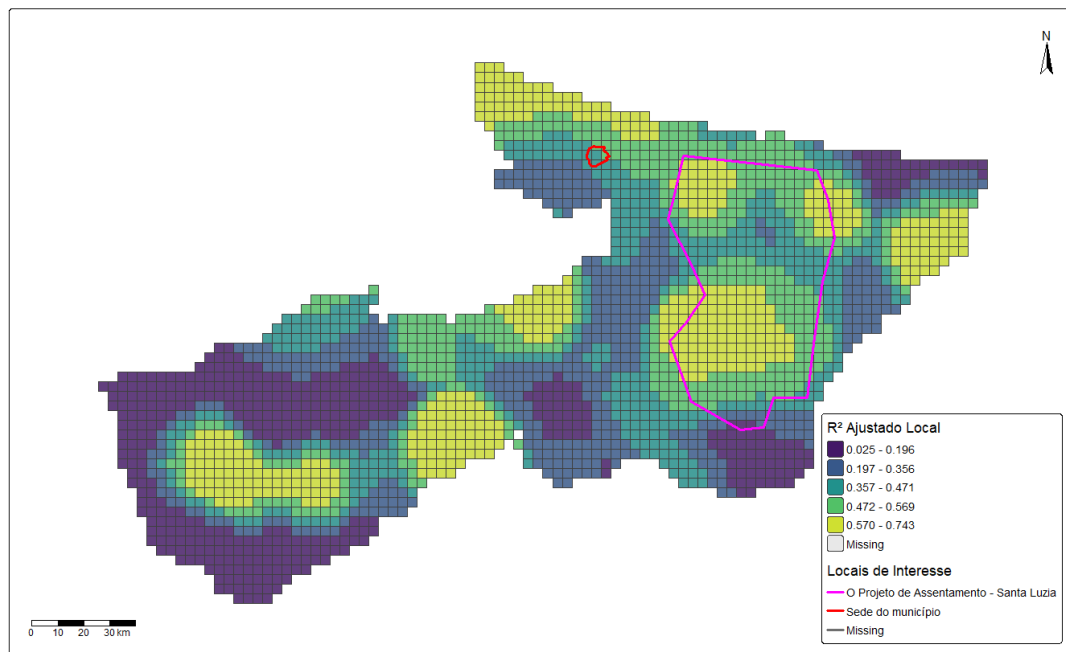
Fonte: Produção do autor (2025).

3.4.2 Análise espacial do Modelo GWR INT_Quad

A distribuição espacial do coeficiente de determinação local (R^2 Ajustado), apresentada na Figura 3.7, permite avaliar a variabilidade da capacidade explicativa do modelo *GWR INT_Quad* ao longo da área de estudo. Diferentemente dos modelos de regressão global, que assumem um ajuste constante para todo o território, o mapa revela uma expressiva heterogeneidade no desempenho do modelo, com valores de ajuste oscilando entre 0.025 e 0.743.

Figura 3.7 - Distribuição dos valores de R^2 Ajustado do modelo *GWR INT_Quad*.

Modelo GWR INTER_Quad



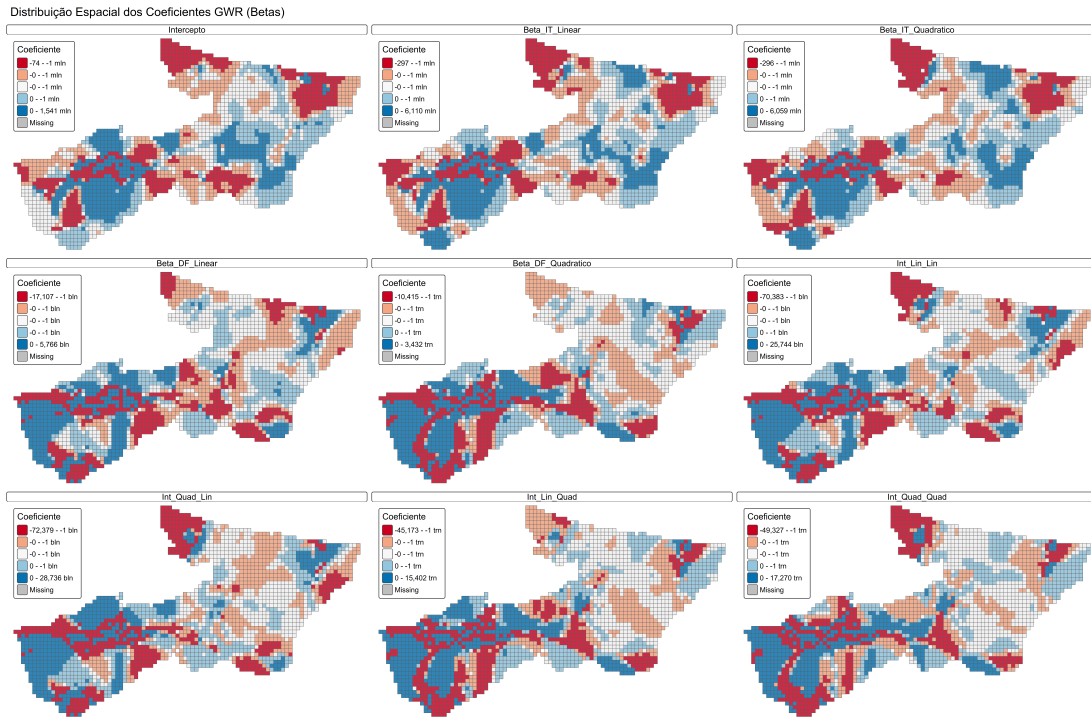
Fonte: Produção do autor (2025).

A distribuição espacial do ajuste do modelo destaca núcleos de maior desempenho (R^2 Ajustado de 0.57 a 0.74) associados a áreas de pressão antrópica, como o Assentamento Santa Luzia e o entorno da Sede do Município. Nestas regiões, as variáveis independentes capturam a variabilidade da biomassa de maneira eficaz, evidenciando a melhor representação local do modelo. Por outro lado, as áreas em tons de roxo indicam regiões onde a capacidade preditiva é inferior, associada principalmente a áreas afastadas de zonas antrópicas ou próximas aos limites do município.

Essa distinção espacial sugere que, nas zonas de baixo R^2 Ajustado, a dinâmica da biomassa pode estar sendo influenciada por variáveis latentes não incorporadas ao modelo ou que a resposta da vegetação aos índices de integridade e distúrbio ocorre de maneira mais complexa nessas sub-regiões (BRUSDON et al., 1996; FOTHERINGHAM et al., 2002). Portanto, o mapeamento reforça a ideia de não-estacionariedade do processo e justifica a necessidade da abordagem local para evitar generalizações que mascarariam essas discrepâncias regionais (FOTHERINGHAM et al., 2002; GUO et al., 2008; COMBER et al., 2020).

A Figura 3.8 apresenta a distribuição espacial dos coeficientes β estimados pelo modelo *GWR INTER_Quad*. Observa-se forte variação espacial em todos os termos, com valores positivos e negativos que indicam mudanças no sentido e na magnitude da influência dos índices florestais sobre a variação da biomassa. O coeficiente linear para Integridade, por exemplo, varia de médias negativas próximas de $-1,04 \times 10^5$ a positivas de $1,29 \times 10^5$, enquanto o termo quadrático correspondente oscila entre $-3,18 \times 10^5$ e $1,04 \times 10^5$. Já os coeficientes associados ao Distúrbio exibem amplitudes ainda maiores, especialmente no componente quadrático, que apresenta médias negativas de $-1,04 \times 10^7$ e positivas de $7,24 \times 10^7$. As interações apresentam os maiores intervalos, variando entre $-5,89 \times 10^7$ e $2,94 \times 10^8$, sugerindo que a combinação entre integridade e distúrbio exerce papel de maior impacto na modelagem local da biomassa no modelo estudado.

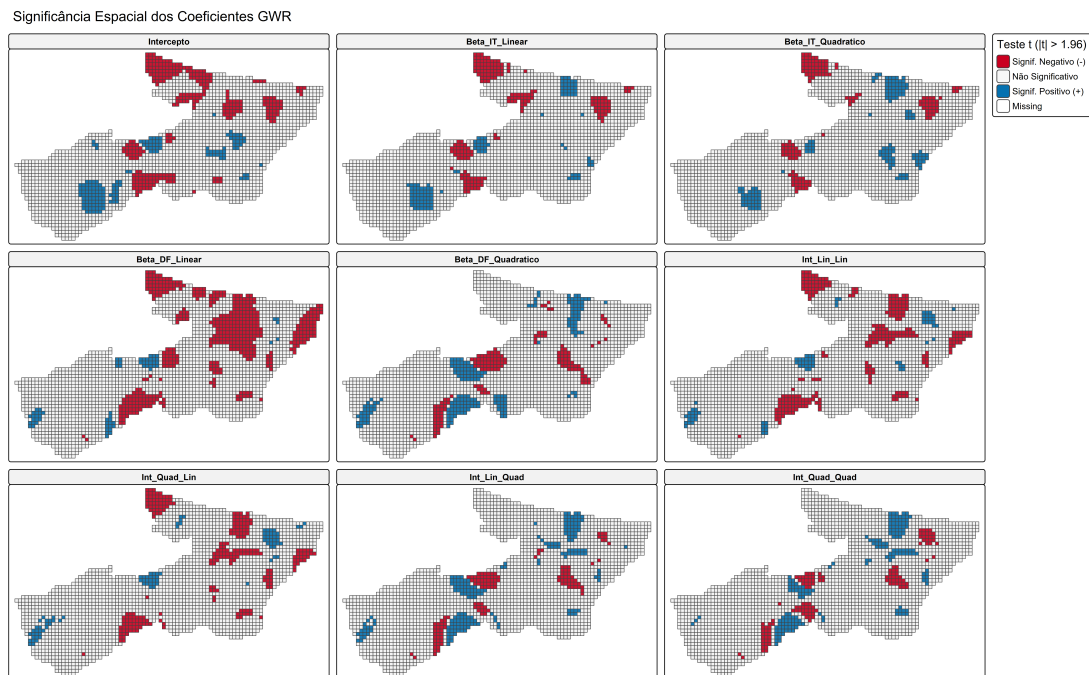
Figura 3.8 - Distribuição dos valores de β do modelo *GWR INT_Quad*.



Fonte: Produção do autor (2025).

A Figura 3.9 apresenta o padrão espacial da significância local dos coeficientes associados à ΔABG no modelo *INTER_Quad*, evidenciando como o sinal e a magnitude da associação variam ao longo do território. Áreas em vermelho indicam coeficientes negativos estatisticamente significativos, sugerindo que incrementos no nível de distúrbio estão associados, localmente, a reduções na biomassa estimada. Em contraste, áreas em azul representam coeficientes positivos significativos, indicando que aumentos nos valores das variáveis explicativas tendem a estar associados a variações positivas locais da biomassa. As células em cinza claro correspondem a coeficientes não significativos, predominantes na maior parte da área, sinalizando ausência de evidência estatística de efeito local nessas regiões.

Figura 3.9 - Distribuição das Células GWR Significativas.



Fonte: Produção do autor (2025).

Dentre os termos estimados no modelo, o coeficiente linear de distúrbio, *Beta_*-

DF_Linear, destaca-se como o driver de maior impacto negativo, apresentando 22% de significância negativa. Esse comportamento é coerente com a relação inversa esperada entre níveis de distúrbio e estoque de biomassa, uma vez que incrementos locais em distúrbio tendem a associar-se a reduções na cobertura florestal e consequentemente na biomassa dessas áreas (??). Em contraste, os coeficientes associados às interações (*Int_Lin_Lin*, *Int_Quad_Lin*, *Int_Lin_Quad* e *Int_Quad_Quad*) e aos termos quadráticos exibem redução de significância, com ausência de sinal estatístico atingindo cerca de 87% da área modelada. As relações positivas significativas ($\beta > 0$) mostram-se espacialmente restritas, variando entre 3% e 9% da área, sugerindo que incrementos locais na biomassa associados aos índices ocorrem de forma pontual.

Para o índice de integridade, os coeficientes *Beta_IT_Linear* e *Beta_IT_Quadrático* também apresentam padrões negativos em parte do território. Esse comportamento pode refletir a própria estrutura dos indicadores que compõem o índice de integridade, pois alguns destes assumem sinais negativos quando associados à degradação, fazendo com que coeficientes negativos expressem uma relação alinhada ao significado matemático do indicador. Ainda assim, tais padrões devem ser interpretados com cautela, pois refletem associações estatísticas locais, e não necessariamente processos causais diretos.

Por fim, o *Intercepto* apresenta predominância de neutralidade (80%), mas retém cerca de 13% de significância negativa e 7% positiva, indicando que fatores não explicitamente modelados parecem modular a biomassa de referência em determinados locais, possivelmente associados ao contexto espacial específico de cada célula.

4 CONCLUSÕES

Os resultados obtidos demonstram que foi possível identificar uma relação entre a variação da biomassa acima do solo e a variação dos índices de integridade (INDIT) e distúrbio florestal (INDDF). Contudo, essa relação mostrou-se fraca e espacialmente heterogênea, indicando que os índices compostos possuem capacidade limitada de explicar as alterações biofísicas na estrutura florestal no período analisado.

Os modelos espaciais confirmaram que formulações que integram simultaneamente integridade e distúrbio fornecem melhor desempenho estatístico. Ainda assim, o poder explicativo moderado, aliado ao predomínio de coeficientes não significativos em grande parte do território, sugere que essa influência ocorre de forma localizada e com baixa intensidade. Parte dessa limitação pode estar associada às incertezas dos dados utilizados. As estimativas de biomassa derivadas de sensoriamento remoto apresentam erros inerentes ao processo de modelagem, e a agregação final em células de 2×2 km tende a suavizar variações locais relevantes, reduzindo o contraste espacial entre áreas mais ou menos impactadas. Essa propagação de incertezas pode contribuir para o enfraquecimento das relações detectadas, o que deve ser considerado na interpretação dos resultados. Dessa forma, no cenário analisado e considerando as limitações decorrentes da escala e dos dados empregados, conclui-se que os índices INDIT e INDDF apresentam potencial explicativo baixo, dada as condições de execução desse trabalho. Esses achados destacam a importância de aperfeiçoar as bases de dados e incorporar variáveis complementares, de modo a fortalecer futuras investigações sobre degradação e mudanças estruturais na paisagem florestal amazônica.

Ainda assim, estudos posteriores poderão aprofundar a análise do efeito da propagação dos erros associados às transformações e estimativas utilizadas, bem como explorar variáveis latentes em regiões onde os modelos apresentaram menor capacidade explicativa, integrando fatores históricos, climáticos e socioeconômicos que influenciam a dinâmica da biomassa. Além disso, os índices podem ser aplicados como variáveis secundárias a modelos preditivos que possuem informações espectrais, podem potencializar o ajuste de modelos relacionados a biomassa. Por fim, recomenda-se avaliar o desempenho de métodos alternativos de dependência espacial e técnicas não lineares ou baseadas em aprendizado de máquina, comparando-os aos modelos empregados neste estudo para verificar potenciais ganhos preditivos.

REFERÊNCIAS BIBLIOGRÁFICAS

AKAIKE, H. Information theory and an extension of the maximum likelihood principle. In: PETROV, B. N.; CSAKI, F. (Ed.). **Proceedings of the 2nd International Symposium on Information Theory**. Budapest: Akademiai Kiado, 1973. p. 267–281. 15

ALMEIDA, C. A. d.; MAURANO, L. E. P.; VALERIANO, D. d. M.; CÂMARA, G.; VINHAS, L.; GOMES, A. R.; MONTEIRO, A. M. V.; SOUZA, A. A. d. A.; RENNÓ, C. D.; SILVA, D. E.; ADAMI, M.; ESCADA, M. I. S.; MOTTA, M. d.; AMARAL, S. **METODOLOGIA PARA MONITORAMENTO DA FLORESTA USADA NOS PROJETOS PRODES E DETER**. São José dos Campos, 2021. Sid.inpe.br/mtc-m21c/2021/01.25.18.31-NTC. Disponível em: <<<http://urlib.net/8JMKD3MGP3W34R/443GTAS>>>. 1

ANSELIN, L. Lagrange multiplier test diagnostics for spatial dependence and spatial heterogeneity. **Geographical Analysis**, v. 20, n. 1, p. 1–17, 1988. 14

_____. **Spatial econometrics: methods and models**. Kluwer Academic Publishers, 1988. Especificamente o Capítulo 3, "Spatial Weights". Disponível em: <<<https://scholar.google.com/scholar?q=Anselin+1988+Spatial+econometrics:+methods+and+models>>>. 13, 14, 15, 25, 26

ANSELIN, L.; BERA, A. K.; FLORAX, R. J. G. M.; YOON, M. J. Simple diagnostic tests for spatial dependence. **Regional Science and Urban Economics**, v. 26, n. 1, p. 77–104, 1996. 14, 25

BACCINI, A.; WALKER, W.; CARVALHO, L.; FARINA, M.; SULLA-MENASHE, D.; HOUGHTON, R. A. Tropical forests are a net carbon source based on aboveground measurements of gain and loss. **Science**, v. 358, n. 6360, p. 230–234, 2017. 1

BAILEY, T. C.; GATRELL, A. C. **Interactive Spatial Data Analysis**. Harlow, Essex: Longman Scientific & Technical, 1995. 13, 14

BOEDEEC, K. L. Sensitivity and specificity of normality tests and consequences on reference interval accuracy at small sample size: a computer-simulation study. **Veterinary Clinical Pathology**, v. 45, n. 4, p. 648–656, 2016. PMID: 27556235. 27

BREUSCH, T. S.; PAGAN, A. R. A simple test for heteroscedasticity and random coefficient variation. **Econometrica**, JSTOR, v. 47, n. 5, p. 1287–1294, 1979. 15, 27

BRUSDON, C.; FOTHERINGHAM, A. S.; CHARLTON, M. E. Geographically weighted regression: a method for exploring spatial nonstationarity. **Geographical Analysis**, v. 28, n. 4, p. 281–298, 1996. 13, 15, 31

- BURNHAM, K. P.; ANDERSON, D. R. **Model Selection and Multimodel Inference: A Practical Information-Theoretic Approach**. 2. ed. New York: Springer, 2002. 27
- CAMELI, M. R. F.; SILVA, S. S. da. Produção do espaço rural de cruzeiro do sul: Um estudo a partir da realidade atual da estrada rural-ramal 12. **Geografia: Ambiente, Educação e Sociedades**, v. 2, n. 6, 2024. 1, 3, 4
- CARNEIRO, T. G. d. S. **Nested-CA: A foundation for multiscale modelling of land use and land cover change**. 109 p. Tese (Doutorado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2006. 6
- CARNEIRO, T. G. d. S.; ANDRADE, P. R. d.; CÂMARA, G.; MONTEIRO, A. M. V.; PEREIRA, R. R. An extensible toolbox for modeling nature–society interactions. **Environmental Modelling & Software**, v. 46, p. 104–117, 2013. 6
- CARVALHO, L. E. X. et al. Regressão linear geograficamente ponderada em ambiente sig. **Transportes**, v. 14, n. 2, p. 200–216, 2006. 15
- CHATFIELD, C.; COLLINS, A. J. **Introduction to multivariate analysis**. [S.l.]: Chapman and Hall, 1986. 25, 26, 27
- CHEN, Y. New approaches for calculating moran’s index of spatial autocorrelation. **PLoS ONE**, v. 8, n. 7, p. e68336, 2013. 14
- _____. An analytical process of spatial autocorrelation functions based on moran’s index. **PLoS ONE**, v. 16, n. 4, p. e0249589, 2021. 27
- COMBER, A.; BRUNSDON, C.; CHARLTON, M.; DONG, G.; HARRIS, R.; LU, B.; LÜ, Y.; MURAKAMI, D.; NAKAYA, T.; WANG, Y.; HARRIS, P. **The GWR route map: a guide to the informed application of Geographically Weighted Regression**. 2020. Disponível em: <<<https://arxiv.org/abs/2004.06070>>>. 16, 31
- CRUZ, R. M. d. **Critérios de informação e seleção de modelos lineares mistos**. Dissertação (Dissertação (Mestrado em Estatística)) — Universidade de São Paulo, São Paulo, 2020. Disponível em: <<<https://www.teses.usp.br/teses/disponiveis/45/45133/tde-17082020-100010/pt-br.php>>>. 27, 28
- EFROYMSON, M. A. Multiple regression analysis. In: RALSTON, A.; WILF, H. S. (Ed.). **Mathematical Methods for Digital Computers**. New York: Wiley, 1960. p. 191–203. 25
- ESCADA, M. I. S.; AMARAL, S.; FERNANDES, D. A. Dinâmicas de ocupação e as transformações das paisagens na amazônia, brasil. **Cadernos de Saúde Pública**, Rio de Janeiro, v. 39, n. 3, p. e00021723, 2023. 24
- FOTHERINGHAM, A. S.; BRUNSDON, C.; CHARLTON, M. **Geographically Weighted Regression: The Analysis of Spatially Varying Relationships**. Chichester: John Wiley & Sons, 2002. 15, 16, 29, 31

FREITAS, C. G. de et al. A produção camponesa de farinha de mandioca na amazônia sul ocidental. **Boletim Goiano de Geografia**, v. 31, n. 2, p. 29–42, 2011. 3, 4

GATTI, L. V. et al. Amazonia as a carbon source linked to deforestation and climate change. **Nature**, v. 595, p. 388–393, 2021. 1, 4

GRANTHAM, H.; DUNCAN, A.; EVANS, T.; JONES, K.; BEYER, H.; SCHUSTER, R.; WALSTON, J.; RAY, J.; ROBINSON, J.; CALLOW, M. Anthropogenic modification of forests means only 40% Nature **Communications**, v. 11, n. 1, p. 5978, 2020. 1

GUO, L.; MA, Z.; ZHANG, L. Comparison of bandwidth selection in application of geographically weighted regression: a case study. **Canadian Journal of Forest Research**, v. 38, n. 9, p. 2526–2534, 2008. 15, 16, 29, 31

HEINRICH, V. H. A.; VANCUTSEM, C.; DALAGNOL, R.; ROSAN, T. M.; FAWCETT, D.; SILVA-JUNIOR, C. H. L.; CASSOL, H. L. G.; ACHARD, F.; JUCKER, T.; SILVA, C. A.; HOUSE, J.; SITCH, S.; HALES, T. C.; ARAGÃO, L. E. O. C. The carbon sink of secondary and degraded humid tropical forests. **Nature**, v. 615, p. 436–442, 2023. 1

HIJMANS, R. J. terra: Spatial data analysis. 2025. R package version 1.8-74. Disponível em: <<<https://rspatial.org/>>>. 6

HURVICH, C. M.; TSAI, C.-L. Regression and time series model selection in small samples. **Biometrika**, Oxford University Press, v. 76, n. 2, p. 297–307, 1989. 29

IBGE. **Malha Municipal Digital da Divisão Político-Administrativa Brasileira 2022**. 2022. Disponível em: <<<https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101998>>>. Acesso em: 19 mar. 2025. 3, 5

_____. **Produção agrícola municipal: culturas temporárias e permanentes – Informativo 2022**. Rio de Janeiro, 2022. 4

INPE. **Monitoramento da cobertura florestal da Amazônia por satélites: sistemas PRODES, DETER, DEGRAD e Queimadas 2007-2008**. São José dos Campos, 2008. Disponível em: <<http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/degrad/arquivos/Relatorio_Prodes2008.pdf>>. Acesso em: 19 mar. 2025. 5

INPE. **Projeto de Monitoramento do Desmatamento na Amazônia Legal por Satélite (PRODES)**. 2022. São José dos Campos: INPE. Disponível em: <<<http://www.obt.inpe.br/prodes>>>. Acesso em: 19 mar. 2025. 2, 4, 5, 6

_____. **Sistema de Detecção do Desmatamento em Tempo Real (DETER)**. 2022. São José dos Campos: INPE. Disponível em: <<<http://www.obt.inpe.br/deter>>>. Acesso em: 19 mar. 2025. 5

_____. **TerraClass: Uso e cobertura da terra na Amazônia Legal**. 2022.

São José dos Campos: INPE. Disponível em:

<<<http://www.inpe.br/terraclass>>>. Acesso em: 19 mar. 2025. 2, 5

KARR, J. R.; LARSON, E. R.; CHU, E. W. Ecological integrity is both real and valuable. **Conservation Science and Practice**, v. 4, n. 2, p. e583, 2022. 1

LAPOLA, D. M.; PINHO, P.; BARLOW, J.; ARAGÃO, L. E.; BERENGUER, E.; CARMENTA, R.; LIDDY, H. M.; SEIXAS, H.; SILVA, C. V.; SILVA-JUNIOR, C. H. The drivers and impacts of amazon forest degradation. **Science**, v. 379, n. 6630, p. eabp8622, 2023. 1

LU, B.; YANG, W.; GE, Y.; HARRIS, P. Improvements to the calibration of a geographically weighted regression with parameter-specific distance metrics and bandwidths. **Computers, Environment and Urban Systems**, v. 71, p. 41–57, 2018. 30

METZGER, J. P.; FONSECA, M. A.; FILHO, F. J. B.; MARTENSEN, A. C. O uso dos modelos em ecologia de paisagens. In: SILVA, J. M. C. (Ed.). **Megadiversidade: Modelagem ambiental e a conservação da biodiversidade**. Belo Horizonte: Conservação Internacional, 2007. p. 64–73. 1

MIOT, H. A. Avaliação da normalidade dos dados em estudos clínicos e experimentais. **Jornal Vascular Brasileiro**, SciELO Brasil, v. 16, n. 2, p. 88–91, 2017. 27

MONTGOMERY, D. C.; RUNGER, G. C. **Applied Statistics and Probability for Engineers**. New York: Wiley, 1994. 25, 27

MORAN, P. A. P. The interpretation of statistical maps. **Journal of the Royal Statistical Society B**, v. 10, p. 243–251, 1948. 13, 14, 15, 16, 24, 27

NETER, J.; KUTNER, M. H.; NACHTSHEIM, C. J.; WASSERMAN, W. **Applied Linear Statistical Models**. 4. ed. [S.l.]: McGraw-Hill, 1996. 25

NOBRE, J.; SINGER, J. Residual analysis for linear mixed models. **Biometrical Journal**, v. 49, n. 6, p. 863–875, 2007. 28, 29

OLIVER, L. **Shifting Boundaries, Shifting Results: The Modifiable Areal Unit Problem**. 2001. Geog 516. Documento online. Disponível em: <<http://ibis.geog.ubc.ca/courses/geog570/talks_2001/scale_maup.html>>. 24

OPENSHAW, S. **The Modifiable Areal Unit Problem**. Norwich: Geo Books, 1984. (Concepts and Techniques in Modern Geography (CATMOG), 38). ISBN 0-86094-134-5. 24

PICKETT, S. T. A.; WHITE, P. S. **The ecology of natural disturbance and patch dynamics**. [S.l.]: Academic Press, 1985. 1

PINHEIRO, J.; BATES, D.; DEBROY, S.; SARKAR, D.; R Core Team. **nlme: Linear and Nonlinear Mixed Effects Models**. [s.n.], 2019. R package version 3.1-141. Disponível em: <<<https://CRAN.R-project.org/package=nlme>>>. 15, 27

RODRIGUES, É. T. **Paisagens florestais associadas a sistemas tecno-produtivos rurais na Amazônia brasileira**. 141 p. Dissertação (Mestrado em Sensoriamento Remoto) — Instituto Nacional de Pesquisas Espaciais (INPE), São José dos Campos, 2024. Disponível em: <<<http://urlib.net/ibi/8JMKD3MGP3W34T/4B3TAF2>>>. 1, 2, 4

RODRIGUES, Ê. T.; MONTEIRO, A. M. V.; ESCADA, M. I. S. Assessing forest landscape disturbance and structural integrity through synthetic indices in the brazilian amazon. **Environmental and Sustainability Indicators**, p. 101009, 2025. 2, 5, 8, 9, 10

SAATY, T. L. Decision making with the analytic hierarchy process. **International journal of services sciences**, v. 1, n. 1, p. 83–98, 2008. 9, 12

SANTORO, M.; CARTUS, O. **ESA Biomass Climate Change Initiative (Biomass_cci): Global datasets of forest above-ground biomass for the years 2007, 2010, 2015, 2016, 2017, 2018, 2019, 2020, 2021 and 2022, v6.0**. [S.l.], abr. 2024. 5, 6

SANTOS, T. S. d.; NETO, J. E. d. S.; SOUZA, E. M. d.; JOSÉ, J. V.; LEITE, K. N.; VALADÃO, M. B. X. Transformações do uso e cobertura do solo na bacia hidrográfica do alto juruá – acre por meio da plataforma mapbiomas. **Research, Society and Development**, v. 14, n. 2, p. e0514248115, 2025. 1

SHAPIRO, S. S.; WILK, M. B. An analysis of variance test for normality (complete samples). **Biometrika**, Oxford University Press, v. 52, n. 3/4, p. 591–611, 1965. 15, 16, 27

SILVA, E. G.; SILVA, S. S. Br-364 – nos confins da fronteira oeste do brasil: uma via para a integração rodoviária do acre (cruzeiro do sul) com ucayalli (pucallpa). **Ciência Geográfica**, v. 24, n. 2, p. 554–555, 2020. 1, 3, 4

SINGER, J. M.; ROCHA, F. M. M.; NOBRE, J. S. Graphical tools for detecting departures from linear mixed model assumptions and some remedial measures. **International Statistical Review**, Wiley Online Library, v. 85, n. 2, p. 290–324, 2017. 25, 28

SOUZA, A. R.; ESCADA, M. I. S.; DAL’ASTA, A. P.; SILVA, M. V. G.; FERNANDES, D. A.; MONTEIRO, A. M. V. Abordagem integrada em saúde-ambiente-economia na amazônia brasileira: mapeando unidades de paisagem da produção. **Cadernos de Saúde Pública**, v. 39, n. 4, p. e00093222, 2025. 1

TORMAN, V. B. L.; COSTER, R.; RIBOLDI, J. Normality of variables: diagnosis methods and comparison of some nonparametric tests by simulation. **Revista do Hospital de Clínicas de Porto Alegre (Rev HCPA)**, v. 32, n. 2, p. 227–234, 2012. 27

TURNER, M. G.; GARDNER, R. H. Introduction to landscape ecology and scale.
In: TURNER, M. G.; GARDNER, R. H. E. (Ed.). **Landscape ecology in
theory and practice: pattern and process**. Berlin: Springer, 2008. [1](#)

ANEXO A - DETALHAMENTO DOS MODELOS ESTATÍSTICOS APLICADOS

Tabela A.1 - Fórmulas e valores dos coeficientes dos modelos concorrentes.

Modelo	Fórmula Estrutural
INTER_Quad	$\Delta AGB = -305,15 + (3527,91 \cdot \Delta INDIT) + (10264,26 \cdot \Delta INDIT^2)$ $- (40107,02 \cdot \Delta INDDF) - (438639,7 \cdot \Delta INDDF^2)$ $- 19307,4(\Delta INDIT \cdot \Delta INDDF) - 225301,3(\Delta INDIT^2 \cdot \Delta INDDF)$ $- 20491,2(\Delta INDIT \cdot \Delta INDDF^2) - 125178,5(\Delta INDIT^2 \cdot \Delta INDDF^2)$ $+ (0,4046 \cdot Wu) + \varepsilon$
INTER_Lin	$\Delta AGB = -1865,99 - (4634,13 \cdot \Delta INDIT) - (62184,51 \cdot \Delta INDDF)$ $- (27661,57 \cdot \Delta INDIT \cdot \Delta INDDF) + (0,3705 \cdot Wu) + \varepsilon$
COMP_FULL_Step	$\Delta AGB = 108,01 - (6514,14 \cdot \Delta IndAC) - (36950,31 \cdot \Delta IndDM)$ $+ (8183,38 \cdot \Delta IndRG) + (0,3803 \cdot Wu) + \varepsilon$
COMP_INDDF_Step	$\Delta AGB = 252,42 - (29731,05 \cdot \Delta IndDM) + (7628,25 \cdot \Delta IndRG)$ $+ (0,4453 \cdot Wu) + \varepsilon$
INDDF_Lin	$\Delta AGB = 82,81 - (47892,97 \cdot \Delta INDDF) + (0,4561 \cdot Wu) + \varepsilon$
INDDF_Quad	$\Delta AGB = 81,94 - (48521,84 \cdot \Delta INDDF) + (3746,32 \cdot \Delta INDDF^2)$ $+ (0,4570 \cdot Wu) + \varepsilon$
COMP_INDIT_Step	$\Delta AGB = -778,14 - (9587,61 \cdot \Delta IndFF) + (3341,92 \cdot \Delta IndAC)$ $+ (2630,37 \cdot \Delta IndPF) + (0,3384 \cdot Wu) + \varepsilon$
INDIT_Lin	$\Delta AGB = -1211,83 - (2028,17 \cdot \Delta INDIT) + (0,2351 \cdot Wu) + \varepsilon$
INDIT_Quad	$\Delta AGB = -1364,66 - (3272,79 \cdot \Delta INDIT) - (1810,23 \cdot \Delta INDIT^2)$ $+ (0,2315 \cdot Wu) + \varepsilon$

Fonte: Produção do autor (2025).

Tabela A.2 - Comparação de desempenho e correlação espacial dos modelos globais concorrentes.

Modelo	AIC	Pseudo - R^2	Lambda (λ)
INTER_Quad	43453,25	0,2708	0,4046
INTER_Lin	43513,11	0,2449	0,3705
COMP_FULL_Step	43527,68	0,2407	0,3803
COMP_INDDF_Step	43585,53	0,2278	0,4453
INDDF_Lin	43603,61	0,2223	0,4561
INDDF_Quad	43605,55	0,2225	0,4570
COMP_INDIT_Step	43843,53	0,1245	0,3384
INDIT_Lin	44027,92	0,0437	0,2351
INDIT_Quad	44029,43	0,0435	0,2315

Fonte: Produção do autor (2025).

Tabela A.3 - Resultados dos testes de normalidade, heterocedasticidade e autocorrelação espacial.

Modelo	Shapiro-Wilk (Estatística ; p-valor)	Breusch-Pagan (Estatística ; p-valor)	I de Moran (Índice ; p-valor)
INDIT_Lin	0,8738 ; < 2.2e-16	46,13 ; < 2.2e-16	-0,0083 ; 0,7669
INDIT_Quad	0,8738 ; < 2.2e-16	52,25 ; < 2.2e-16	-0,0080 ; 0,7592
INDDF_Lin	0,9063 ; < 2.2e-16	78,89 ; < 2.2e-16	-0,0213 ; 0,9735
INDDF_Quad	0,9065 ; < 2.2e-16	132,07 ; < 2.2e-16	-0,0214 ; 0,9742
INTER_Lin	0,9082 ; < 2.2e-16	177,83 ; < 2.2e-16	-0,0144 ; 0,9024
INTER_Quad	0,9177 ; < 2.2e-16	220,61 ; < 2.2e-16	-0,0168 ; 0,9346
COMP_INDIT_Step	0,8914 ; < 2.2e-16	62,37 ; < 2.2e-16	-0,0140 ; 0,8958
COMP_INDDF_Step	0,9048 ; < 2.2e-16	179,34 ; < 2.2e-16	-0,0199 ; 0,9643
COMP_FULL_Step	0,9024 ; < 2.2e-16	195,17 ; < 2.2e-16	-0,0149 ; 0,9106

Fonte: Produção do autor (2025).