

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CENTRO DE CIÊNCIAS BIOLÓGICAS E DA SAÚDE
PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIAS AMBIENTAIS

GABRIEL GOMES DE CARVALHO

Análise Espaço-Temporal dos Municípios Brasileiros: aplicações
de Aprendizado de Máquina na Integração de Dados Territoriais e
Populacionais

SÃO CARLOS - SP
2025

GABRIEL GOMES DE CARVALHO

Análise Espaço-Temporal dos Municípios Brasileiros: aplicações de
Aprendizado de Máquina na Integração de Dados Territoriais e
Populacionais

Dissertação apresentada ao Programa de Pós-Graduação em Ciências Ambientais da Universidade Federal de São Carlos, como parte dos requisitos para a obtenção do título de Mestre em Ciências Ambientais¹.

Orientadora: Prof.^a Dr.^a Norma F. L. S. Valencio
Coorientadora: Prof.^a Dr.^a Heloísa de Arruda Camargo

São Carlos-SP
2025

¹ Apoio: O presente trabalho foi realizado com apoio da Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), Brasil. Processo nº 2023/03000-3

Carvalho, Gabriel Gomes de

Análise espaço-temporal dos municípios brasileiros:
aplicações de aprendizado de máquina na integração de
dados territoriais e populacionais / Gabriel Gomes de
Carvalho -- 2025.

107f.

Dissertação (Mestrado) - Universidade Federal de São
Carlos, campus São Carlos, São Carlos

Orientador (a): Norma Felicidade Lopes da Silva
Valencio

Banca Examinadora: Silvia Cristina de Jesus, Tathiane
Mayumi Anazawa, Rafael Alves Orsi

Bibliografia

1. Dinâmicas municipais. 2. Aprendizado de máquina. 3.
Integração de dados. I. Carvalho, Gabriel Gomes de. II.
Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática
(SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Arildo Martins - CRB/8 7180



UNIVERSIDADE FEDERAL DE SÃO CARLOS

Centro de Ciências Biológicas e da Saúde
Programa de Pós-Graduação em Ciências Ambientais

Folha de Aprovação

Defesa de Dissertação de Mestrado do candidato Gabriel Gomes de Carvalho, realizada em 13/05/2025.

Comissão Julgadora:

Profa. Dra. Norma Felicidade Lopes da Silva Valencio (UFSCar)

Profa. Dra. Silvia Cristina de Jesus (UFSCar)

Prof. Dr. Rafael Alves Orsi (UNESP)

Profa. Dra. Tathiane Mayumi Anazawa (UNICAMP)

O Relatório de Defesa assinado pelos membros da Comissão Julgadora encontra-se arquivado junto ao Programa de Pós-Graduação em Ciências Ambientais.

DEDICATÓRIA

Dedico este trabalho às boas memórias que carrego do meu avô
Beto.

AGRADECIMENTOS

A toda minha família, em especial à minha mãe, que sempre me apoiou emocionalmente e financeiramente nos momentos mais difíceis dessa caminhada, que durante toda a trajetória me lembrou do poder da educação como instrumento de transformação.

A Prof.^a Dr.^a Norma Valencio, que me instruiu desde o começo de minha caminhada científica crítica, que me alinhou ao método e ao nível que a ciência precisa ter, além de compartilhar muitas experiências das quais me lembrarei para o resto da vida.

A Prof.^a Dr.^a Heloísa Arruda de Camargo, que esteve presente e disponível para complexificar minhas dúvidas, sempre com bom humor.

Aos professores e amigos do Departamento de Ciências Ambientais da Universidade Federal de São Carlos. Aos professores Frederico Yuri Yanai e Rodolfo Antonio de Figueiredo, ambos por sua sensibilidade e carinho ao ministrar as disciplinas, favorecendo o desenvolvimento do espírito acadêmico e do interesse na área ambiental; aos professores, Celso Maran de Oliveira e Vandoir Bourscheidt, que sempre estiveram de portas abertas às minhas perguntas e conversas de final de tarde; a professora Andréa Teixeira e ao professor Marcel Tanaka por compartilharem momentos fora das salas os quais aliviaram a minha rotina de estudos; ao professor Luciano Elsinor e a professora Patrícia Ferreira por ouvirem ativamente as minhas ideias e “me darem corda”; a Professora Renata Bovo Peres por me convidar a participar da reunião de laboratório, a qual achei muito interessante e proveitosa; ao Professor Juliano por ouvir atentamente minhas dúvidas durante as aulas de economia. A Prof.^a Dr.^a Silvia Cristina de Jesus, que além de se tornar uma amiga, me auxiliou com as técnicas e referências em sistemas de informações geográficas.

Ao Arthur Valencio, amigo de viagens e de ensinamentos que guardei com muito carinho, entre eles o mais notável: a paciência;

A Fundação de Amparo à Pesquisa do Estado de São Paulo (FAPESP), por conceder o apoio em formato de bolsa para a realização dessa pesquisa.

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

EPÍGRAFE

“Como a inovação é permanente, todos os dias acordamos um pouco mais
ignorantes e indefesos.”

Milton Santos

RESUMO

De Carvalho, G. G. – Análise Espaço-Temporal dos Municípios Brasileiros: aplicações de Aprendizado de Máquina na Integração de Dados Territoriais e Populacionais. 2025 – Número de páginas: Dissertação (Mestrado) – Universidade Federal de São Carlos, Centro de Ciências Biológicas e da Saúde, Programa de Pós-Graduação em Ciências Ambientais, São Carlos – 2025.

Este estudo buscou explorar as dinâmicas territoriais, demográficas e ambientais dos municípios brasileiros por meio de uma abordagem de dados integrada baseada em aprendizado de máquina. A pesquisa se justifica pela necessidade de compreender como diferentes características municipais se relacionam e evoluem ao longo do tempo, considerando aspectos como mudanças na configuração territorial, padrões de uso e cobertura da terra, além de transformações demográficas. A metodologia adotada envolve a coleta e processamento de dados provenientes de bases oficiais, como o IBGE e o MapBiomas, permitindo a construção de um conjunto de dados estruturado e adequado para a aplicação de técnicas estatísticas e de inteligência artificial. A primeira etapa consiste na definição do município como unidade de análise, considerando sua institucionalização e evolução ao longo do tempo. Um enfoque especial é dado ao período de 2003 a 2023, quando houve uma estabilização nos processos emancipatórios. Além disso, são analisadas as diferenças regionais na formação municipal, destacando como cada macrorregião brasileira apresenta padrões distintos de criação e expansão dos municípios. Na sequência, foram investigadas as características territoriais dos municípios, abrangendo aspectos como extensão territorial, variações espaciais e fatores ambientais que influenciam sua configuração. A partir disso, foram elaboradas inferências estatísticas para avaliar diferenças significativas entre os municípios, utilizando métodos como ANOVA para compreender variações entre grupos regionais. A pesquisa avança com a aplicação de técnicas supervisionadas e não supervisionadas de aprendizado de máquina. Por fim, foram utilizadas técnicas de Explainable Artificial Intelligence (XAI) para interpretar os modelos gerados e compreender a importância de cada variável no comportamento municipal. A identificação de que a formação dos clusters de municípios, baseados em características territoriais, populacionais e ambientais, correspondem mais aos biomas naturais do Brasil do que às divisões tradicionais por estado ou região. Assim, municípios com características ambientais e de uso do solo semelhantes, mesmo que pertencentes a diferentes estados, foram agrupados em clusters com alta homogeneidade, demonstrando a força de abordagens baseadas em dados e em aprendizado de máquina para a identificação de padrões espaciais que fogem das divisões políticas-administrativas. Dessa forma, a dissertação propõe um

novo olhar sobre a organização municipal no Brasil, combinando diferentes fontes de dados e metodologias para aprofundar a compreensão das transformações ocorridas no território nacional.

Palavras-chave: Dinâmicas Municipais; aprendizado de máquina; integração de dados

ABSTRACT

This study sought to explore the territorial, demographic, and environmental dynamics of Brazilian municipalities through an integrated data approach based on machine learning. The research is justified by the need to understand how different municipal characteristics relate to each other and evolve over time, considering aspects such as changes in territorial configuration, land use and land cover patterns, and demographic transformations. The methodology adopted involves the collection and processing of data from official databases, such as IBGE and MapBiomas, allowing the construction of a structured dataset suitable for the application of statistical and artificial intelligence techniques. The first step consists of defining the municipality as the unit of analysis, considering its institutionalization and evolution over time. A special focus is given to the period from 2003 to 2023, when there was a stabilization in the emancipatory processes. In addition, regional differences in municipal formation are analyzed, highlighting how each Brazilian macro-region presents distinct patterns of creation and expansion of municipalities. Next, the territorial characteristics of the municipalities were investigated, covering aspects such as territorial extension, spatial variations, and environmental factors that influence their configuration. From this, statistical inferences were drawn to assess significant differences between municipalities, using methods such as ANOVA to understand variations between regional groups. The research advances with the application of supervised and unsupervised machine learning techniques. Finally, Explainable Artificial Intelligence (XAI) techniques were used to interpret the generated models and understand the importance of each variable in municipal behavior. The identification that the formation of clusters of municipalities, based on territorial, population, and environmental characteristics, correspond more to the natural biomes of Brazil than to the traditional divisions by state or region. Thus, municipalities with similar environmental and land use characteristics, even if belonging to different states, were grouped into highly homogeneous clusters, demonstrating the strength of data-based and machine learning approaches for identifying spatial patterns that escape political-administrative divisions. Thus, the dissertation proposes a new look at municipal organization in Brazil, combining different data sources and methodologies to deepen the understanding of the transformations that have occurred in the national territory.

Keywords: Municipal Dynamics; Machine Learning; Data Integration

LISTA DE FIGURAS

Figura 1. Tabela de dados após pré-processamento.	33
Figura 2. Pipeline metodológico.	37
Figura 3. Mapas de extensão territorial gerados a partir de diferentes classes de tamanho de extensão.	45
Figura 4. Testes de Kruskal-Wallis para variáveis de área nas Macrorregiões.	46
Figura 5. Teste de Dwass-Steel-Critchlow-Fligner com variáveis de área para macrorregiões.	47
Figura 6. Mapas coropléticos de representação da variação proporcional de área municipal total, reduzida ou acrescentada por três períodos de tempo (2003-2012, 2012-2023 e 2003-2023).	48
Figura 7. Estatística descritiva dos dados populacionais dos municípios brasileiros.	58
Figura 8. Estatística descritiva dos dados populacionais dos municípios brasileiros por Macrorregião.	60
Figura 9. Teste de Kruskal-Wallis para variáveis de população por Macrorregião. Elaboração: o autor.	61
Figura 10. Teste de Kruskal-Wallis para variáveis de população por Unidade da Federação.	61
Figura 11. Teste de comparações múltiplas Dwass-Steel-Critchlow-Fligner para variáveis de população por Macrorregião.	62
Figura 12. Mapas de variação proporcional de população.	63
Figura 13. Mapa do Brasil gerado pelo algoritmo KMeans, considerando variáveis territoriais, populacionais e ambientais.	87
Figura 14. Árvore de decisão gerada pelo algoritmo de Floresta Aleatória.	89

LISTA DE GRÁFICOS

Gráfico 1. Gráficos de quantidade de municípios e proporção de municípios por grandes regiões do Brasil.	39
Gráfico 2. Gráfico com a variação percentual de municípios em períodos intercensitários.	42
Gráfico 3. Séries temporais municipais para variável extensão territorial de 2003 a 2023 na abrangência das grandes regiões.	48
Gráfico 4. Séries temporais municipais para variável extensão territorial de 2003 a 2023 na abrangência das Unidades da Federação (UF).	49
Gráfico 5. Matriz de correlação entre variáveis da dimensão territorial.	51
Gráfico 6. Séries temporais de populações municipais por macrorregiões do Brasil.	55
Gráfico 7. Séries temporais de populações municipais por unidades da federação do Brasil.	56
Gráfico 8. Matriz de correlação entre variáveis da dimensão demográfica.	63
Gráfico 9. Séries temporais cobertura florestal percentual municipais por macrorregião.	65
Gráfico 10. Séries temporais cobertura florestal percentual municipais por unidade da federação do Brasil.	66
Gráfico 11. Séries temporais de cobertura de área não vegetada percentual municipais por macrorregião do Brasil.	67
Gráfico 12. Séries temporais de cobertura de área não vegetada percentual municipais por unidades da federação do Brasil.	68
Gráfico 13. Séries temporais de pares de cobertura das terras municipais Brasil.	70
Gráfico 14. Séries temporais de pares de cobertura das terras municipais por macrorregiões do Brasil.	71
Gráfico 15. Séries temporais de pares de cobertura das terras municipais por Unidades da Federação do Brasil.	72
Gráfico 16. Testes de Cotovelo e Silhueta aplicados em diferentes normatizações de dados.	82
Gráfico 17. Lista de atributos mais importantes para clusterização via KMeans usando XAI (Shapley values).	87

LISTA DE TABELAS

Tabela 1. Variáveis selecionadas.	28
Tabela 2. Descrição das variáveis selecionadas	29
Tabela 3. Variáveis geradas.	31
Tabela 3. Classificações municipais baseadas em população municipal.	53
Tabela 4. Distribuição de municípios nos clusters gerados pelo algoritmo KMeans, segundo a técnica de normalização aplicada.	82
Tabela 5. Distribuição de municípios nos clusters gerados pelo algoritmo DBSCAN, segundo a técnica de normalização aplicada.	83
Tabela 6. Distribuição de municípios nos clusters gerados pelo algoritmo Agglomerative Clustering, segundo a técnica de normalização aplicada.	84

TABELA DE ABREVIATURAS

AM - Aprendizado de Máquina

CNM - Confederação Nacional de Municípios

DPA - Divisão Política-administrativa

DTB - Divisão Territorial Brasileira

FNDE - Fundo Nacional de Desenvolvimento da Educação

IA - Inteligência Artificial

IBGE - Instituto Brasileiro de Geografia e Estatística

ML - Machine Learning

UF - Unidades da Federação

XAI - A Explainable Intelligence Artificial

SUMÁRIO

SUMÁRIO	15
1 INTRODUÇÃO GERAL	16
1.1. Apresentação do tema, revisão bibliográfica, problematização e justificativa	16
1.2 Objetivos	24
1.2.1 Objetivo Central	24
1.2.2 Objetivos Específicos	24
1.3 Metodologia	25
1.3.1 Revisão bibliográfica	25
1.3.2 Seleção das bases de dados	26
1.3.3 Coleta e armazenamento de dados	26
1.3.4 Restrições éticas, políticas de preservação e estratégias de compartilhamento	27
1.3.5 Seleção dos atributos	27
1.3.6 Pré-processamento de dados	30
1.3.7 Engenharia de funcionalidades	30
1.3.8 Análise Exploratória e Descritiva	32
1.3.9 Aprendizado de Máquina: supervisionado e não-supervisionado	33
1.3.10 Explainable Artificial Intelligence (XAI) e Feature Importance Analysis	34
1.3.11 Softwares utilizados	34
1.4 Estrutura da Dissertação	37
2 O MUNICÍPIO COMO UNIDADE DE ANÁLISE: DEFINIÇÕES E DIMENSÕES	38
2.1 A definição institucional de município no Brasil	38
2.2 Características territoriais dos municípios brasileiros, o n-município.	38
2.3 Dinâmicas de extensão territorial e seus padrões de classificação	42
2.3. Dinâmicas demográficas municipais e seus padrões de classificação	52
2.4. Uso e cobertura da terra nos municípios: dinâmicas e padrões espaciais	64
2.5. Estratificações existentes e a necessidade de novas abordagens	73
2.6 Resultados do capítulo	74
3 APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA ANÁLISE MUNICIPAL	78
3.1. A evolução do uso de técnicas computacionais na geografia e nas ciências ambientais	78
3.2. Aprendizado de máquina e análise espacial: potencialidades para o estudo municipal	79
3.3 Aplicação de aprendizado de máquina na análise integrada de variáveis territoriais, demográficas e ambientais (LULC)	80
3.3.1 Análise Experimental de Técnicas de Clusterização e Classificação	80
3.4 Avaliação das limitações e desafios do uso de IA na interpretação desses dados	89
4 CONSIDERAÇÕES FINAIS	90
3.1. Padrões e dinâmicas municipais identificadas a partir da análise integrada	91
REFERÊNCIAS	94
ANEXOS	102
APÊNDICES	103

1 INTRODUÇÃO GERAL

1.1. Apresentação do tema, revisão bibliográfica, problematização e justificativa

Os municípios constituem as unidades fundamentais e de menor abrangência da organização político-administrativa do Estado brasileiro, sendo dotados de personalidade jurídica e autonomia. Fundamentados na Constituição Federal de 1988, Capítulo 1, Artigo 18, os municípios são concebidos não apenas como divisões territoriais, mas como entes políticos que exercem funções essenciais para a promoção do desenvolvimento local e a efetivação da cidadania (Brasil, 1988). Essa autonomia financeira, política e administrativa possibilita a implementação de políticas públicas mais adequadas às especificidades locais e regionais, seguindo o princípio da descentralização do poder (Resende, 2008; Arretche, 2010; Andrade; Caldas, 2025). Segundo o Instituto Brasileiro de Geografia e Estatística (2023a), o município é definido sendo: “Unidade federativa autônoma de caráter local cuja criação, incorporação, fusão ou desmembramento se faz por lei estadual, observada a continuidade territorial”. Para Zagallo (2022), os municípios são: “espaços de deliberação política que consideram as particularidades de cada lugar e compreendem a importância do ambiente local e dos modos de vida existentes”.

Dimensões territoriais, demográficas e padrões de uso e ocupação da terra são essenciais para compreender a complexidade dessas unidades. A caracterização dos municípios é um fator essencial para a formulação de políticas públicas e a gestão ambiental, pois permite identificar padrões de urbanização, desenvolvimento socioeconômico e impactos ambientais em diferentes contextos regionais (Maia; Quadros, 2009). O conceito de região foi, e ainda é explorado como método auxiliar para pesquisas em diversas dimensões: sociais, ambientais e econômicas. O agrupamento de elementos em conjuntos traz a possibilidade de identificar e organizar dados a partir de características semelhantes, estruturando um conhecimento geográfico sob o território em diversas escalas (IBGE, 2011). Para Santos (1997) uma região é um *locus* de determinadas funções da sociedade total em um momento dado, trazendo o conjunto de capitais fixos geografizados (fixos), segundo uma lógica do momento de criação, mais a ação da sociedade sob estes, sendo denominados como *formas-conteúdo*, propondo uma visão de região como uma construção histórica e social, estruturada por elementos materiais, mas cuja função e significado são determinados pelas relações sociais em determinado tempo, sendo objetos técnicos animados

pelo movimento da sociedade. Assim, a região é tanto resultado quanto meio das transformações sociais, um espaço onde a sociedade imprime sua lógica e onde se desdobram as suas ações.

A dimensão territorial de um município refere-se à sua delimitação geográfica, área total, posição geoespacializada, fronteiras e hierarquias político-administrativas. No Brasil, os limites municipais são estabelecidos por meio de legislação estadual e federal, sendo sistematizados pelo Instituto Brasileiro de Geografia e Estatística (IBGE), que é a principal entidade responsável pelo mapeamento e atualização da malha municipal. A Divisão Territorial Brasileira (DTB), disponibilizada pelo IBGE, define os contornos aproximados de cada município (conforme legislação e órgãos municipais e estaduais), garantindo a integridade de sua área e prevenindo conflitos de jurisdição. Essa delimitação é expressa em mapas digitais e bases cartográficas contínuas, que permitem análises espaciais detalhadas e elaboração de estudos geoestatísticos (IBGE, 2023a).

Além da extensão territorial, outro fator relevante para a caracterização municipal é a classificação do espaço geográfico. Municípios podem ser predominantemente urbanos, rurais ou apresentar uma composição mista, explorando a compreensão de *continuum* rural-urbano-natureza (IBGE, 2023b), o que influencia sua organização socioeconômica e ambiental. A diferenciação entre municípios urbanos e rurais é fundamental para o planejamento territorial local e regional e a implementação de políticas públicas, especialmente em áreas relacionadas à infraestrutura e à conservação ambiental (Peretta, 2025).

A dimensão de uso e a ocupação da terra refere-se à forma como os municípios distribuem seus espaços entre áreas urbanizadas, agrícolas, florestais, corpos d'água e outras categorias de cobertura da terra. A análise dessas características é essencial para entender os impactos ambientais e as dinâmicas econômicas dos territórios municipais. Entre as principais fontes de dados já classificadas sobre o uso da terra no Brasil encontra-se o MapBiomas, uma rede colaborativa de ONGS, universidades, laboratórios e startups que utilizam imagens de satélite para mapear anualmente as transformações no território nacional. Com base nesses dados, é possível classificar os municípios segundo a predominância de cobertura do solo, identificando áreas de expansão urbana, desmatamento, regeneração florestal, entre outros fenômenos (MAPBIOMAS, 2023).

A dimensão demográfica de um município é frequentemente utilizada para compreender seu perfil socioeconômico e socioambiental (Sposito, 2024). Entre os fatores analisados nesta dimensão, destacam-se: o tamanho populacional e a taxa de crescimento populacional. (Gomes; Matos; Lobo, 2020). As estimativas populacionais de cada município também são consideradas

informações relevantes para a organização territorial, sendo informação fundamental ao Tribunal de Contas da União (TCU) para a distribuição de recursos através do Fundo de Participação dos Municípios (FPM) e Fundo de Participação dos Estados (FPE), fontes de recursos indispensáveis para grande parte dos municípios de pequeno porte (CNM, 2024).

Assim, a definição de um município brasileiro envolve múltiplas dimensões, cada uma respaldada por fontes oficiais que oferecem dados geoespaciais, demográficos e socioeconômicos. O IBGE se destaca como o principal órgão responsável pela padronização dessas informações, por meio de censos, mapas e estatísticas populacionais e territoriais. No Brasil, não existe uma tipologia oficial única para a classificação dos municípios. Entretanto, instituições governamentais e de pesquisa utilizam diferentes critérios para categorizar e/ou estratificar os municípios, partindo de análises multivariadas, que consideram indicadores municipais e regionais, conforme suas necessidades específicas (Sposito, 2024).

O Censo Demográfico, realizado pelo IBGE a cada dez anos, é a principal e mais utilizada fonte de dados sobre a população brasileira, incluindo aspectos como crescimento populacional, densidade demográfica, estrutura etária e distribuição espacial (IBGE, 2023c). Entretanto, essa pesquisa possui limitações devido ao seu intervalo temporal de dez anos e a sua ausência de explicações relacionadas aos perímetros urbanos e vazios municipais (Pera; Bueno, 2016).

A descrição de perfis municipais, pesquisa de Informações Básicas Municipais (MUNIC), é uma das principais ferramentas oficiais que retrata essa diversidade municipal através da totalidade de municípios do País, fornecendo informações diversas sobre a gestão pública municipal, incluindo legislação vigente e os instrumentos de planejamento existentes nessa esfera da administração (IBGE, 2023d). Entre os principais tópicos envolvidos, encontram-se: recursos humanos e perfil do gestor municipal, trabalho e inclusão produtiva, direitos humanos, cultura, educação e saúde.

O IBGE, como principal órgão responsável pela produção de estatísticas oficiais no Brasil, disponibiliza uma ampla gama de informações sobre demografia, economia, infraestrutura urbana e rural, além de delimitações territoriais que servem de referência para a organização espacial do país. Essas informações são fundamentais para análises que envolvem a caracterização municipal e a identificação de padrões estruturais do território. A organização do MapBiomas, por meio do uso de técnicas avançadas de sensoriamento remoto e aprendizado de máquina, fornece uma série histórica detalhada sobre a cobertura e o uso da terra no Brasil, possibilitando o monitoramento de mudanças ambientais em escalas temporal e espacial.

Diversos estudos acadêmicos utilizam dimensões territoriais, como a extensão municipal, fronteiras, e a geolocalização, baseando-se nos dados fornecidos pelo Instituto Brasileiro de Geografia e Estatística. Essas pesquisas abrangem áreas diversas – realçando o espaço como categoria fundamental – como demografia, planejamento urbano, análise ambiental e áreas interdisciplinares.

As fronteiras territoriais do Brasil desempenham um papel fundamental na configuração geopolítica, econômica e socioambiental do país. A importância estratégica das fronteiras brasileiras – terrestres e marítimas – se manifesta em múltiplas dimensões. No âmbito econômico, essas áreas abrigam importantes corredores comerciais e logísticos, sendo essenciais para o escoamento da produção agrícola e industrial brasileira, além de possibilitarem o fortalecimento das relações comerciais com os países vizinhos. Aspectos relacionados à segurança pública e ao crime organizado também são temas relacionados às fronteiras (Hoinatski, 2025), pois permitem lidar com a integração das forças policiais, com o compartilhamento de dados e informações de inteligência territorial, um vetor de enfrentamento à criminalidade. Questões humanitárias e culturais também estão associadas às regiões de fronteira. Velasco (2019), descreve as funções primárias das fronteiras: “buscam a delimitação territorial, isto é, uma delimitação entre comunidades políticas, [...] buscam regular o trânsito”. Entretanto, com o crescimento de tendências nacionalistas e discursos contra a imigração, essas regiões, de maneira generalizada, apresentam diversos tipos de violência (Paula; Correia, 2013) contra aqueles que não se enquadram como o “migrante ideal”, além de abrigarem populações vivendo na informalidade, em um processo de vulnerabilização acentuado.

Do ponto de vista socioambiental, as regiões fronteiriças apresentam desafios relacionados à preservação dos biomas, ao controle do desmatamento, à gestão dos recursos hídricos compartilhados e ao combate a atividades ilegais, como o tráfico de drogas e a exploração ilegal de minérios (Becker, 2010; 2012). Como menciona a referida autora:

Paradoxalmente, um espaço de fluxos, de vetores, calcado na comunicação e na velocidade acelerada, tende a superar o espaço dos lugares, as fronteiras e os Estados. As sociedades territorialmente localizadas perdem autonomia em face dos atores da escala mundial que agem segundo uma lógica global em grande parte por elas ignorada e não controlada, em unidades que por seu tamanho e transnacionalidade permanecem acima das pressões sociais e controles políticos, e cujas comunicações e decisões se pautam em informações e instruções recebidas segundo a posição de cada local na rede de trocas, e não segundo valores sociais e culturais das localidades (Becker, 2012).

Assim, sem desconsiderar a mundialização perversa (Santos, 1996, p. 21) na qual os municípios e a federação estão inseridos, explorar as questões fronteiriças das municipalidades considerando as particularidades traz aos estudos uma abordagem mais holística frente a problemáticas socioambientais locais, já que essas, desconhecem os limites políticos administrativos (Monteiro, Anazawa e Oliveira; 2020; Freitas e Barcellos; 2025). Diante desse contexto, compreender as características e as dinâmicas das fronteiras brasileiras e áreas limítrofes é essencial para a formulação de políticas públicas que promovam a integração territorial, o desenvolvimento sustentável e a segurança nacional.

As áreas limítrofes municipais, no contexto exclusivamente nacional, correspondem aos territórios onde diferentes jurisdições municipais compartilham limites geográficos diretos. Esses municípios vizinhos, também denominados municípios contíguos ou confinantes, interagem territorialmente e administrativamente, sendo separados por limites naturais ou artificiais (IBGE, 2023e). Cada município exerce sua autonomia administrativa dentro de seus limites, porém, as interações nessas áreas limítrofes são fundamentais para a análise de impactos geográficos, sociais e econômicos entre os entes municipais.

As questões fronteiriças e territoriais não podem ser dissociadas das dinâmicas populacionais que ocorrem nesses espaços. A dimensão territorial exige uma leitura integrada da questão demográfica em um par dialético, que se ergue e se sustenta frente a uma realidade complexa e multifacetada.

Dessa forma, compreender as dinâmicas territoriais exige uma leitura articulada com os fluxos populacionais que ocorrem dentro e entre os limites municipais. A produção e o acesso a dados demográficos entendendo suas granularidades tornam-se fundamentais para aprofundar essa análise.

Os dados territoriais provenientes do IBGE possuem diversas aplicações, sendo amplamente utilizados para subsidiar decisões governamentais e novos estudos acadêmicos. Na área de planejamento urbano, informações sobre densidade populacional e crescimento demográfico orientam a criação de infraestrutura e políticas habitacionais. No setor da educação, a distribuição da população por faixa etária auxilia na alocação de escolas e investimentos em ensino (Santos, 2025). Na saúde pública, os dados territoriais permitem identificar unidades ou regiões com maior necessidade de serviços hospitalares, por exemplo frente a desastres, além de promoverem uma articulação regional que supere os limites técnicos e financeiros municipais em situações de emergência (Freitas; Barcellos, 2025). Ainda no que diz respeito à saúde, com foco na epidemiologia, Barcellos *et al.* (2024) utilizaram dados territoriais aliados a dados

demográficos e ambientais para compreender a expansão e o aumento da incidência de dengue no Brasil entre 2014 e 2020 para antecipar a tomada de decisão.

Estudos sobre a pandemia da SARS-CoV-2 (COVID-19) também utilizaram dados do território entremeados a outras dimensionalidades. Entre esse universo de estudos, nota-se as reflexões trazidas por Peres (2020), sobre os efeitos da crise deflagrada pela pandemia de COVID-19 nas cidades médias paulistas, demonstrando que, algumas cidades médias do Estado de São Paulo são consideradas de alto risco de dispersão da COVID-19, devido à sua importância e influência regional, reforçando o aspecto relacionado à *fixos* e *fluxos* do planejamento regional. Para Santana *et al.* (2024), o uso de geotecnologias aliado a dados territoriais, possibilitou a identificação de clusters de alto e baixo risco de incidência e mortalidade por COVID-19 na Região Metropolitana de São Paulo (RMSP) durante o período de 2020 a 2022, analisando sua relação com variáveis socioeconômicas e demográficas. Explorando um recorte sociotemporal aproximado (contexto paulista de propagação da COVID-19), Monteiro, Anazawa e Oliveira (2020) exploraram a crise sanitária e de planejamento a partir da COVID-19 na região metropolitana do Vale do Paraíba e Litoral Norte, destacando as dificuldades de organização territorial em um contexto de crise, avaliando a relação de governança do Estado frente aos municípios. Imbricando fatores como distribuição de casos positivos de óbitos, perfil demográfico, processo de urbanização, densidade e saneamento, Do Carmo e Teixeira (2020) exploraram como a situação dos indivíduos, de famílias e dos grupos populacionais em relação às suas matrizes de acesso influenciam sua capacidade de enfrentamento à COVID-19, realçando aspectos do processo de urbanização incompleta, explicado em detalhes por Milton Santos (2005).

A análise demográfica dos municípios, ao ser integrada à dimensão de uso e cobertura das terras, possibilita uma compreensão mais ampla das dinâmicas territoriais e socioeconômicas. A distribuição populacional, a densidade demográfica e o crescimento urbano influenciam diretamente as transformações na paisagem, promovendo processos de expansão urbana, conversão de áreas naturais em zonas agrícolas ou industriais e alterações na disponibilidade de recursos ambientais, em razão disso é necessário associar ambas as dimensões com aquelas relacionadas ao uso e cobertura das terras (Vanwey; D'Antona; Brondízio, 2007; Côrtes; D'Antona, 2014). As dinâmicas associadas ao uso e a cobertura das terras (*e.g.*, expansão da fronteira agrícola, urbanização, desmatamento, restauração ecológica) mostram-se como dados potenciais para determinar futuros cenários do planeta (UN-HABITAT, 2024). A compreensão dessas dinâmicas mostra-se capital e vem se tornando mais populares entre estudos e relatórios técnicos. Esse crescimento de estudos que utilizam da dimensão territorial, mais especificamente

ao uso e cobertura das terras, pode ser atribuído também, à crescente demanda populacional por terras e alimentos (Afuye *et al.*, 2024).

Com o avanço das tecnologias de geoprocessamento e de sensoriamento remoto, torna-se mais viável a utilização de bases de dados geoespaciais como os disponibilizados pela organização MapBiomias (Souza *et al.*, 2020). Diversos estudos recentes têm se beneficiado dessas bases de dados para analisar mudanças ambientais e territoriais em diferentes níveis e divisões políticas administrativas.

No referente aos biomas, Franca Rocha *et al.* (2024) investigaram a dinâmica de áreas queimadas na Caatinga de 1985 a 2023, usando técnicas de aprendizado profundo e imagens de satélite, com o objetivo de avaliar modelos de detecção de fogo, analisar padrões espaciais e temporais das áreas afetadas e oferecer informações cruciais para o manejo e prevenção de incêndios. Utilizando de dados não-estruturados, Souza *et al.* (2025), demonstraram a perda de extensão de áreas de água superficial após a seca de 2023 na Amazônia, desencadeando efeitos negativos às populações locais e à biodiversidade, reforçando a vulnerabilidade das populações amazônicas às mudanças climáticas. Conciliando o uso de indicadores de biodiversidade e cobertura das terras, Rabeschini *et al.* (2025), apresentaram o aumento da pressão da expansão agrícola sobre a biodiversidade, sugerindo o incremento de mais informações para o detalhamento do fenômeno.

No que se refere a bacias hidrográficas, Santos *et al.* (2025), objetiva a identificação de condutores e efeitos resultantes do desflorestamento na bacia hidrográfica do Juruá/AC, sendo um território importante para conservação de reservas extrativistas e populações tradicionais. Em Lopes *et al.* (2025), foram analisadas as mudanças espaço-temporais do uso da terra e seus impactos na fragmentação da vegetação do Cerrado na Bacia do Rio Paracatu em um horizonte de 30 anos, os resultados mostraram uma redução no grupo florestal entre 1990 e 2020, enquanto houve um aumento nas classes de agricultura, silvicultura e mineração no mesmo período. A pesquisa de Oliveira *et al.* (2025) avaliou as nascentes e suas respectivas áreas de Preservação Permanente (APPs) na microbacia do riacho Algodoads, área de influência do Porto de Suape, utilizando de geotecnologias como mapas temáticos e levantamento de dados quantitativos, resultando no aumento da área urbanizada e da formação florestal em razão da redução das áreas de rios, lagos e oceanos.

Estudos envolvendo outros recortes administrativos também utilizaram desse banco de dados visto a sua flexibilidade de processamento. Usando a escala de macrorregião, Fialho *et al.* (2024), buscaram analisar espaço-temporalmente as transições florestais na Reserva da Biosfera

da Mata Atlântica (RBMA), com foco na ecorregião da Serra do Mar no Sudeste, ao longo de 37 anos. O objetivo foi compreender as transições no período estudado, com destaque para os padrões espaciais e temporais das dinâmicas florestais em toda a área, considerando os limites políticos e naturais. Conforme demonstrado por Da Silva *et al.* (2024), é possível utilizar dados relacionados ao uso e cobertura da terra, integrado aos dados de rodovias e regiões geográficas dentro do contexto de uma região ainda mais ampla, sendo esse, o arco do desmatamento, definido pelos municípios com maior intensidade de desmatamento na região da Amazônia legal.

A evolução das áreas urbanizadas reflete mudanças econômicas, sociais e técnico-informacionais ao longo da história, influenciada por crescimento populacional, inovações em infraestrutura e alterações nas dinâmicas de trabalho e consumo (Santos, 2005). O estudo apresentado por Rosario e Filho (2024) analisaram a evolução do uso e ocupação das áreas urbanizadas no município de Lauro de Freitas/BA entre 1985 e 2022, investigando como essas mudanças moldaram as configurações espaciais atuais e sua conexão com a área em que está inserido, no caso, a região metropolitana de Salvador. O estudo, ainda, apresenta uma particularidade, apresentar a fragmentação territorial do município.

A integração das dimensões territorial, demográfica e de uso e cobertura das terras é essencial para compreender as dinâmicas municipais, uma vez que o território define os limites físicos, administrativos e hierarquias, a demografia reflete a ocupação humana e suas dinâmicas socioeconômicas, e o uso e cobertura da terra revelam os padrões de apropriação e transformação do espaço. No entanto, apesar da ampla disponibilidade de dados provenientes de fontes como o IBGE e o MapBiomas, os desafios persistem na harmonização dessas informações para análises integradas.

Estudos que integrem os dados de múltiplas dimensões e regiões estão se multiplicando na literatura em vários campos de conhecimento, como nos da Demografia (Silva *et al.*, 2024), Planejamento Urbano (Aguiar; Baptista, 2023), Ciências Ambientais (Vilar *et al.*, 2016; Favero *et al.*, 2024) e Ciências Sociais (Ribeiro, 2022); porém, com a popularização das técnicas e avanços tecnológicos, isso pode ser potencializado. A Inteligência Artificial (IA) desempenha um papel fundamental na integração de bases de dados multidimensionais, permitindo a análise conjunta de variáveis territoriais, demográficas e de uso e cobertura da terra. Algoritmos de aprendizado de máquina e análise espacial avançada possibilitam o cruzamento de grandes volumes de dados heterogêneos, extraindo padrões, correlações e tendências que poderiam passar despercebidos em abordagens tradicionais (Albahri *et al.*, 2024; Tasnuva *et al.*, 2024).

A Inteligência Artificial permite uma maior interoperabilidade entre diferentes bases de dados, como os censos do IBGE e os mapas de cobertura da terra do MapBiomias. Métodos de processamento de linguagem natural (PLN) podem ser utilizados para extrair informações de documentos administrativos e relatórios municipais, enquanto modelos de visão computacional analisam imagens de satélite para detectar transformações territoriais. Dessa forma, a combinação dessas técnicas contribui para a construção de análises mais robustas e para a formulação de políticas públicas mais precisas, baseadas em evidências derivadas da interação entre múltiplas dimensões espaciais e sociais.

Assim, procedimentos de triangulação desses bancos de dados abrem novas possibilidades para pesquisas acadêmicas e aplicação de técnicas de inteligência artificial e aprendizado de máquina, permitindo a criação de modelos e análises espaciais. Assim, foram elaboradas perguntas norteadoras: de que forma a análise integrada de bases de dados territoriais, demográficas e ambientais pode aprimorar a compreensão das dinâmicas municipais no Brasil? As diferentes macrorregiões do país apresentam padrões distintos na configuração e evolução territorial dos municípios? Quais são as vantagens e desafios do uso de metodologias de aprendizado de máquina na exploração de grandes bases de dados municipais? E, por fim, quais técnicas de aprendizado de máquina são mais adequadas para identificar padrões e tendências nesses dados?

1.2 Objetivos

1.2.1 Objetivo Central

Diante das questões acima, o objetivo central desta pesquisa é testar algumas metodologias de aprendizado de máquina que possam contribuir na análise integrada de bancos de dados relacionados às dimensões territoriais, demográficas e de uso e cobertura do solo utilizando dados com granularidade municipal no contexto brasileiro. A análise conjunta dos dados do MapBiomias com as informações do IBGE permite identificar padrões de ocupação do solo e suas relações com atividades econômicas, como agricultura e urbanização, além de avaliar tendências de desmatamento, degradação de biomas e mudanças no regime hídrico dos territórios.

1.2.2 Objetivos Específicos

Analisar a configuração territorial dos municípios brasileiros e suas variações em diferentes escalas (nacional, macrorregiões e unidades da federação), considerando critérios como extensão territorial e população.

Investigar a evolução do uso e cobertura da terra nos municípios brasileiros entre 2003 e 2023, com ênfase nas transformações ambientais como desmatamento, expansão agrícola e alterações em corpos d'água e suas correlações.

Aplicar técnicas de aprendizado de máquina (como clusterização e classificação) para identificar padrões espaciais e temporais nos dados territoriais, demográficos e ambientais em nível municipal.

Explorar a relação entre variáveis demográficas e ambientais por meio de métodos explicáveis de Inteligência Artificial (XAI), visando compreender os fatores que contribuem para diferentes dinâmicas territoriais.

1.3 Metodologia

1.3.1 Revisão bibliográfica

A etapa inicial da pesquisa consistiu em uma revisão bibliográfica sistemática e integrativa, essencial para embasar teoricamente o estudo e garantir que a metodologia adotada esteja alinhada com os avanços recentes na literatura acadêmica. O objetivo principal desta revisão foi compreender os conceitos fundamentais relacionados à definição e caracterização de municípios brasileiros, bem como abordagens analíticas de cunho crítico aplicadas à avaliação de dinâmicas territoriais, demográficas e de uso e cobertura das terras. A seleção da bibliografia foi conduzida utilizando bases de dados científicas reconhecidas, como: (a) Scopus (Elsevier), (b) Web of Science (WoS) e (c) Google Scholar, este último citado, utilizado preferencialmente para ampliar a busca de relatórios técnicos, dissertações e teses.

A busca sistemática seguiu um conjunto estruturado de palavras-chave e operadores booleanos para garantir abrangência e precisão na recuperação de artigos. Exemplos de termos utilizados incluem: ("municipalista" OR "federalismo"), ("tipologias municipais" OR "agrupamento municipal"), ("distribuição populacional" OR "arranjos demográficos"), ("Uso e cobertura da terra" OR "LULC"), ("aprendizado de máquina" OR "*machine learning*").

Além disso, foram utilizados filtros de inclusão e exclusão para filtrar estudos relevantes, priorizando a literatura recém atualizada (últimos 5 anos), artigos revisados por pares, artigos de acesso aberto e estudos que utilizem bases de dados semelhantes às empregadas nesta pesquisa.

Assim, a revisão foi dividida em três eixos principais:

1. Definição e caracterização dos municípios brasileiros – incluindo aspectos históricos, políticos e administrativos.
2. Análise espacial e estatística aplicada à dinâmica municipal – abordando o uso de dados territoriais e socioeconômicos na modelagem e agrupamento de municípios.
3. Aplicação de Inteligência Artificial em estudos territoriais e ambientais – investigando a utilização de técnicas de aprendizado de máquina para categorização e previsão de dinâmicas espaciais.

Os resultados dessa revisão serviram como base para a seleção das variáveis, escolha dos métodos estatísticos e interpretação dos padrões identificados na pesquisa.

1.3.2 Seleção das bases de dados

A pesquisa utilizou bases de dados oficiais e de instituições reconhecidas, selecionadas com base em critérios de abrangência temporal e espacial, granularidade e confiabilidade. Entre as principais fontes de dados estão:

- IBGE (Instituto Brasileiro de Geografia e Estatística): fornecendo informações demográficas, socioeconômicas e territoriais (Censo populacional, estimativas de população, malhas municipais - DPA e divisão territorial brasileira - DTB).
- Map Biomas: disponibilizando dados sobre cobertura e uso da terra em diferentes períodos e níveis hierárquicos, permitindo a análise da dinâmica ambiental dos municípios, através de dados estatísticos provenientes da coleção 9 de uso, cobertura e transição das terras (<https://doi.org/10.58053/MapBiomas/2W2Z5M>).

A seleção dessas bases visou garantir uma análise robusta e coerente, cobrindo aspectos demográficos, territoriais e ambientais dos municípios brasileiros.

1.3.3 Coleta e armazenamento de dados

Após a seleção das bases de dados, foi realizada a etapa de coleta, organização e armazenamento dos dados. A coleta envolveu o download dos arquivos necessários, considerando diferentes formatos (CSV, shapefiles, GeoTIFFs, entre outros), e a vinculação dos *datasets* por meio de identificadores comuns, como códigos de municípios do IBGE (Geocode). Todos os dados utilizados na pesquisa foram coletados de bases de dados abertas.

Para garantir a integridade, acessibilidade e reprodutibilidade da pesquisa, os dados são armazenados e organizados no Google Drive do projeto. Esse repositório centralizado permite a facilidade de compartilhamento, garantindo que todos os arquivos estejam disponíveis para consulta e processamento em diferentes etapas da análise. Buscou-se adaptar o repositório ao método Kimball (Nambiar; Mundra, 2022; Chikhalkar *et al.*, 2025). Esse fluxo garante transparência e replicabilidade na pesquisa, possibilitando futuras atualizações e expansões do estudo.

1.3.4 Restrições éticas, políticas de preservação e estratégias de compartilhamento

O processo de extração resguardará os direitos de propriedade dos dados de origem, cuja menção será obrigatória nos produtos gerados pela pesquisa bem como será advertido aos usuários destes produtos que tal menção é mandatória, caso façam uso dos mesmos. Não será focado dados sensíveis, que requeiram proteção à identidade. Tanto o modo de disponibilização dos dados pelas fontes quanto as escalas adotadas e o tipo dos dados extraídos não requerem providências de proteção à identidade, pois o objeto de estudo não é individual (pessoa física). Trata-se, na unidade menor, de municípios; na escala intermediária de agregação, de UFs e, na escala mais abrangente de agregação, da União no que tange às suas respectivas características territoriais, demográficas, finanças públicas, eleitorais e afins.

1.3.5 Seleção dos atributos

Com os dados organizados, a próxima etapa foi a seleção das variáveis (*features*). Esse processo é baseado em critérios como relevância teórica, qualidade dos dados e contribuição potencial para os modelos de IA. As variáveis podem ser agrupadas em diferentes dimensões, sendo:

- Territoriais e ambientais (área municipal absoluta, área relativa de cada classe de ocupação de terra, variações de área total do município, variações de área de classe relativa de uso e cobertura das terras e geolocalização).
- Demográficas (população absoluta, população estimada, variação populacional).

A seleção cuidadosa das features é essencial para garantir que a análise capte padrões relevantes e diferenciadores entre os municípios, reduzindo a presença de variáveis redundantes ou irrelevantes.

Esse estudo examina um período de 21 anos, de 2003 a 2023, usando um conjunto de variáveis territoriais, demográficas e ambientais. A fim de demonstrar o conjunto de 10 variáveis coletadas inicialmente, a tabela 1 detalha o nome da variável, unidade (quando houver), tipo e a fonte.

Tabela 1. Variáveis selecionadas			
Variável	Unidade	Tipo	Fonte
Geocode		Numérico (Único)	DTB - IBGE
Grandes regiões		Catégorica	DPA - IBGE
UF		Catégorica	DTB - IBGE
Area_KM2	Km ²	Numérico (Real)	DPA - IBGE
População	Individual	Numérico (Inteiro)	Censo - IBGE
População estimada	Individual	Numérico (Inteiro)	E.P. - IBGE
Classe de cobertura	Hectare	Numérico (Inteiro)	Map Biomas
Ano	Individual	Numérico (Inteiro)	IBGE/Map Biomas

Tabela 1. Variáveis selecionadas. Elaboração: o autor.

A seleção dessas variáveis visa fornecer um panorama abrangente das características municipais, permitindo a análise integrada de fatores demográficos, espaciais e ambientais. Uma breve descrição textual relacionada a cada variável é apresentada no quadro 1.

Variável	Descrição
Geocode	O código geográfico do município, também conhecido como código IBGE, é um identificador único utilizado para padronizar e facilitar a vinculação dos dados municipais provenientes de diferentes fontes. Ele é essencial para a integração de múltiplas bases de dados.
Grandes regiões	Esta variável representa a divisão do Brasil em cinco macrorregiões: Norte, Nordeste, Centro-Oeste, Sudeste e Sul. Essas regiões são estabelecidas pelo IBGE com base em critérios geográficos, socioeconômicos e culturais, sendo fundamentais para análises comparativas de padrões espaciais e variações regionais.
UF	Representa os 26 estados brasileiros e o Distrito Federal. A UF é uma variável categórica relevante para a análise das dinâmicas municipais dentro de cada estado, permitindo a avaliação de possíveis diferenças nas características socioeconômicas e ambientais entre as unidades federativas.
Area_KM2	Expressa a extensão territorial de cada município em quilômetros quadrados.
População	Representa o número total de habitantes do município com base no Censo Demográfico.
População estimada	Estimativa do número de habitantes do município em um determinado ano, com base em projeções populacionais do IBGE.
Classe de cobertura	Obtida a partir do MapBiomias, essa variável indica a categoria de uso e cobertura da terra predominante no município em um determinado período. As classes incluem formações naturais (como florestas, campos e corpos d'água) e áreas antrópicas (como agricultura, pastagem e áreas urbanizadas). Essas classes são organizadas conforme níveis de hierarquia (MapBiomias, 2023).

Tabela 2. Descrição das variáveis selecionadas. Elaboração: o autor. Fonte: IBGE (2017); MapBiomias (2023).

1.3.6 Pré-processamento de dados

Os dados coletados são limpos e transformados para garantir qualidade e compatibilidade entre as diferentes fontes. Esse pré-processamento pode incluir: (a) Tratamento de valores ausentes, seja por imputação estatística ou exclusão seletiva; (b) Normalização e padronização de variáveis, garantindo que atributos com escalas distintas sejam comparáveis, interferindo no resultado de métodos estatísticos modelos de aprendizado de máquina baseado em distâncias (c) Conversão de formatos e integração espacial, para permitir o uso conjunto dos dados em análises estatísticas e modelagens de IA (Escovedo; Koshiyama; 2020; Dias *et al.*, 2024). Esta etapa é fundamental para garantir robustez e confiabilidade nos resultados da pesquisa, após essas verificações e tratamentos (quando necessário).

1.3.7 Engenharia de funcionalidades

Além da seleção inicial das variáveis, algumas novas variáveis derivadas podem ser criadas a partir dos dados brutos. A engenharia de funcionalidades extrai informações mais representativas, agregando inteligência ao modelo analítico. Essas novas variáveis são justificadas com base em sua capacidade preditiva e interpretabilidade, buscando a maior eficiência e qualidade dos modelos subsequentes (IBM, 2025).

Durante essa etapa, é possível verificar e comparar os dados do MapBiomias em relação à base de dados do IBGE, especialmente no que diz respeito à área territorial. Além disso, gera-se novas variáveis com o objetivo de aprimorar tanto a análise exploratória quanto os modelos gerados, conforme apresentado na Tabela 2. A variável `área_total_ha` refere-se a somatória de todas as classes de uso e cobertura de nível 1. Com ela, é possível comparar a área total indicada pela base MapBiomias, com a extensão municipal representada pela variável `Area_Km2` disponibilizada pelo IBGE. A `Classe_%`, representa a proporção de cobertura de terras referente a determinada ocupação (Anexo 2), onde a somatória de todas as classes equivale à totalidade de terras do município, demonstrando uma estrutura composicional de dados (Aitchison, 1982).

Tabela 2. Variáveis geradas

Variável	Unidade	Tipo	Fonte
area_total_ha	Hectare	Numérico (Real)	MapBiomias
Classe_%	Percentual	Numérico (Real)	MapBiomias
VAR_Classe_2003_2012	Percentual	Numérico (Real)	MapBiomias
VAR_Classe_2012_2023	Percentual	Numérico (Real)	MapBiomias
VAR_Classe_2003_2023	Percentual	Numérico (Real)	MapBiomias
VAR_2003_2012		Numérico (Real)	DPA - IBGE
VAR_2012_2023		Numérico (Real)	DPA - IBGE
VAR_2003_2023		Numérico (Real)	DPA - IBGE
PROP_VAR_2003_2012	Percentual	Numérico (Real)	DPA - IBGE
PROP_VAR_2012_2023	Percentual	Numérico (Real)	DPA - IBGE
PROP_VAR_2003_2023	Percentual	Numérico (Real)	DPA - IBGE
VAR_POP_2003_2012		Numérico (Real)	Censo - IBGE / E.P. - IBGE
VAR_POP_2012_2023		Numérico (Real)	Censo - IBGE / E.P. - IBGE
VAR_POP_2003_2023		Numérico (Real)	Censo - IBGE / E.P. - IBGE
PROP_VAR_POP_2003_2012	Percentual	Numérico (Real)	Censo - IBGE / E.P. - IBGE
PROP_VAR_POP_2012_2023	Percentual	Numérico (Real)	Censo - IBGE / E.P. - IBGE
PROP_VAR_POP_2003_2023	Percentual	Numérico (Real)	Censo - IBGE / E.P. - IBGE

Tabela 3. Variáveis geradas. Elaboração: o autor.

Ao final da etapa de pré-processamento de dados, foi estruturado um novo conjunto de dados no formato longo (*long format*), uma abordagem que facilita análises temporais e modelagens estatísticas. Nesse formato, a primeira coluna contém o identificador único de município (Geocode), enquanto a segunda coluna corresponde ao ano respectivo. As colunas subsequentes armazenam todas as variáveis originalmente coletadas, além das novas variáveis derivadas do processo de engenharia de funcionalidades (Figura 1). A escolha pelo formato longo, em oposição ao formato largo (*wide format*), permite maior flexibilidade para operações como agrupamentos, análise de tendências temporais e aplicação de algoritmos de aprendizado de máquina que lidam com séries temporais e variações espaciais.

pecoode ano	1. Forest	2. Non Forest Natural Format	3. Farming	4. Non Vegetated Area	5. Water	6. Non Observed	area_total	proporcao_1. Forest	proporcao_2. Non Forest Natural Format	proporcao_3. Farming
1100015	18955697612447667229	89295 74911138954	32325 5882951418	243 121911541748	14275 28486840592	0 261555627441406	705862 2505042781	0.8071847507916414	0.12645066236028168	0.04579858761411725
1100015	189856673 2207919	89397 67941390787	33596 458485907	281 62943869291	14952 900889334	0 261555627441406	705862 2505042652	0.805728038802717	0.1252391229562303	0.047598320682754
1100015	1897554295 4859195567	84260 1172031464	37619 4769907358	298 607775671387	18387 9523906621	0 610227502441406	705862 2505042745	0.7994413719011438	0.1193718889904964	0.052367568144672
1100015	1898557012 07789189185	86195 1310714562	45153 2699142071	318 21164031982	17182 866253847	0 6077399255711094	705862 2505042828	0.7891229068008345	0.12211324763781543	0.06396895405895807
1100015	1899502035 0910175227	81139 3811913425	52035 6771466811	385 12002908619	12016 300265636	0 610259130895013	705862 2505042952	0.7820718444748496	0.1291177579263552	0.07123851971291396
1100015	1900549951 605269256	83741 50670729639	51970 9540454663	390 52290775870	19817 1385111688	0 52306331781094	705862 2505042813	0.779120295604029	0.11863717971193125	0.07362761503159757
1100015	1991544748 839527686	78754 89267240765	57086 6286775832	390 849645013429	24900 6958838337	0 348671875	705862 2505042816	0.771494972746422	0.11157268070253282	0.08084666018185021
1100015	1992540658 854507418	76795 69499777387	60846 5880295555	395 40094868049	27185 3530337605	0 348671875	705862 2505042598	0.765951904371958	0.1087699919199803	0.08620178909733914
1100015	1993533963 399725292	78220 4121708676	68227 74514078	398 10062329039	27346 651423713	0 348671875	705862 2505042633	0.756044664424732	0.1079033564869664	0.096698116513226
1100015	1994523425 820584113	76507 0766266666	79606 5019937431	402 926913836672	25919 6754423003	0 348671875	705862 2505042655	0.7415408891468275	0.108388911194961954	0.11277908939913919
1100015	1995515752 69435257657	90703 29386834086	89688 06209872488	410 978412674563	10386 87434449399	0 348634765625	705862 2505042562	0.7306704586966245	0.12849999219895607	0.12553166134863072
1100015	1996509203 97869479786	82617 44634332209	99948 811077885	414 129017657472	16846 5367022083	0 348671875	705862 2505042454	0.7154837626456801	0.11848425999412316	0.14185881152335888
1100015	1997495650 111776546	78995 81027306226	109937 307359079	425 156110747219	20942 706743184	0 348671875	705862 2505042425	0.7020646319645848	0.1119130183536821	0.15574895424099764
1100015	199848991 0466789402	79384 5655639006	116411 261905654	429 444401275638	20645 5830771794	0 348671875	705862 2505042322	0.6927570450603213	0.11244647070961756	0.16449205105124386
1100015	1999478974 700043912	76544 324380345	126547 805730921	431 465727930121	22363 4947836	0 348671875	705862 2505042397	0.678566817389192	0.1084089071810842	0.1792013054295015
1100015	2000470241 4337310019	91053 71840266335	137254 9154239736	437 058348852544	6875 0374142272	0 0871678719712656	705862 2505042301	0.6661943366395182	0.1289664136310276	0.18445000146182886
1100015	2001461272 73611794185	86143 7598242249	147240 39789916578	438 139644793707	10767 0734502076	0 0871678719712656	705862 2505042116	0.6534833198384064	0.1220404860799152	0.208566041960935
1100015	2002452309 38994850645	83318 53384666669	156732 0136304075	442 748914429717	13059 5863868641	0 0	705862 2505042066	0.6407898561266252	0.11803796108308396	0.22204334276041116
1100015	2003440789 86124653985	84861 49011455718	168489 01767162635	444 22407026255	11189 9367883076	0 0	705862 2505042035	0.6244576397015551	0.1203739154334718	0.2388957282922155
1100015	2004434032 494824301	85292 4213676087	175473 93020318518	454 73642358404	10608 667378898	0 0	705862 2505042243	0.6148968789788434	0.1208343143966967	0.2486561473920486
1100015	2005427437 9924060956	86397 87396360648	180209 4007519309	458 27427124028	9538 65621773534	0 08716789875	705862 2505042332	0.6059544013613471	0.12244027338660228	0.2578823284927906
1100015	2006420418 82168801299	89164 88078086311	185750 919872557	460 862910524173	6464 8287681893	0 174326075	705862 2505042123	0.6007104300380294	0.12623235646677992	0.28313463072737276
1100015	2007420663 998380966	89565 4654294448	199083 1217687074	466 28989000337	7053 10007472677	0 4358399231972656	705862 2505042277	0.5956576363341548	0.12551359040414336	0.2678753845152424
1100015	2008418313 8151251107	89991 8402748846	191573 60213308509	470 402294134527	6612 58886030673	0 0	705862 2505042126	0.5926281152636951	0.1260738670303582	0.2714036651153739
1100015	2009418111 62817901165	90796 00892330482	191920 43976421995	471 7150652823029	6560 40567630309	0 0	705862 250504222	0.5922481872721398	0.1259007619190187	0.2718903203157486
1100015	2010417616 7378501004	90000 09039698906	192488 4390151918	473 871964162656	5271 82796873162	0 0	705862 250504254	0.591639196507009	0.127714444347363176	0.277413473763176
1100015	2011417189 38488245866	89738 9498675887	193066 55748935743	475 478328735357	5391 87966192635	0 0	705862 2505042166	0.5910351269733663	0.1271337959528673	0.27351874583879265
1100015	2012416786 2973218995	89535 71511899217	193613 27186307916	480 379325121	5446 58867880877	0 0	705862 2505042198	0.5904640700422398	0.12864587454939521	0.27429327992077991
1100015	2013417137 197871187	90340 41933740909	193529 8973824918	484 460763115237	4270 0109690938	0 0871678719712656	705862 2505042132	0.59157761385278	0.1275028035797123	0.274173120816964
1100015	2014417188 332237894	89596 6589531167	193991 68989347206	494 20713720093	4591 3534043579	0 0	705862 2505042098	0.591033657267788	0.1269322149347287	0.276903209007013
1100015	2015415088 5918321631	90322 1944194867	196145 671966672	500 508315411381	3805 27897028809	0 0	705862 2505042213	0.5889589187701301	0.12796002832893918	0.2778804890648193
1100015	201641510 688259548	90706 6447531312	196776 637108814	508 62455012819	3881 29694328004	0 348671875	705862 2505042256	0.5844961847018954	0.1277836818001304	0.2816052569914654
1100015	2017406529 3176869473	90384 647602266	201440 99562013217	509 260101074223	3908 09376624145	0 435847583007813	705862 2505042048	0.580183056105375	0.12804565406858778	0.2853821253701215
1100015	2018405967 0248129471	90234 00412950431	205053 290308782	513 8110953680424	4093 99312404174	0 087175244140625	705862 2505041996	0.575136330810953	0.12783206405564125	0.2905004324735594
1100015	2019401163 4457075013	91611 12345394381	209626 4581019455	516 96155643476	4394 55160446167	0 0	705862 25050402	0.568331666881786	0.12773191000203084	0.29689726726784873
1100015	2020396289 476329853	91842 3303842381	213087 45015410118	518 19881203033	4124 2323979581	0 61017550650197	705862 2505041849	0.5614260797324472	0.130116258914041654	0.30180246592941654
1100015	2021390473 5514629775	90196 3060029087	220397 63616324623	513 39917558942	4277 69641314275	0 261503631501797	705862 2505041908	0.5531866187338764	0.1227708886023755	0.31227886646645756
1100015	2022381466 7351554007	82708 48109221009	225985 17457677273	518 624404809359	5185 79943804659	0 435839969091797	705862 2505041885	0.5404265898501827	0.117169435018184248	0.33432185161836646
1100015	1986269093 464304451	864 1495917652	73481 8519313008	1744 434091897993	634 87491486296	0 0	442608 48490022117	0.909624165448933	0.01952951471261883	0.166018123893991
1100023	1986346991 7450169576	8482 580441351242	81713 422347625	2049 742894140684	670 993713042312	0 0	442608 4849002552	0.7900710340955155	0.0191491497588893455	0.18461783951832095
1100023	1987343174 79895348195	8459 156882843524	88178 99381662642	2151 932711859193	643 602568589304	0 0	442608 48490025976	0.7754618214744661	0.01911206306923669	0.19922675183996117
1100023	1988340683 2213168228	8041 9908617436	90463 12661415742	2540 750796142644	720 607307117733	0 0	442608 4849002408	0.770010180830016	0.018199542249466	0.204305579835049
1100023	1989339769 3639740677	7818 8958275155	91182 9476187043	3082 46621028006	756 812013488768	0 0	442608 48490027233	0.7676521701806993	0.017696989794812763	0.20601265165899733

Figura 1. Tabela de dados após pré-processamento. Elaboração: o autor.

1.3.8 Análise Exploratória e Descritiva

A análise exploratória e descritiva dos dados representa uma etapa fundamental para compreender a distribuição, os padrões e as possíveis inconsistências no conjunto de dados utilizado. Esse processo permite uma visão inicial sobre as variáveis coletadas e geradas, identificando tendências, correlações e possíveis outliers que possam influenciar as análises subsequentes (Gotelli *et al.*, 2010).

Durante o desenvolvimento dos capítulos, foram calculadas estatísticas descritivas para as variáveis de interesse presentes no conjunto de dados, incluindo medidas de tendência central (mediana), medidas de dispersão (variância) e limites (máximo e mínimo). Essas estatísticas forneceram uma visão preliminar sobre a distribuição de cada variável e auxiliaram na identificação de possíveis discrepâncias ou distribuições enviesadas que poderiam impactar os modelos de aprendizado de máquina.

Além das estatísticas descritivas, foram gerados gráficos para visualizar os padrões e tendências das variáveis ao longo do tempo e entre diferentes regiões. Histogramas foram utilizados para examinar a distribuição das variáveis e *boxplots* permitiram a detecção de valores atípicos. Adicionalmente, mapas temáticos foram elaborados para visualizar espacialmente a distribuição de algumas variáveis de interesse, possibilitando a identificação de padrões territoriais que poderiam não ser evidentes em análises puramente numéricas.

Outro aspecto essencial da análise exploratória foi a avaliação das correlações entre as variáveis, utilizando uma matriz de correlação de Pearson para variáveis contínuas e a correlação de Spearman para variáveis não lineares. Essa etapa foi fundamental para entender a

interdependência entre diferentes variáveis e fornecer subsídios para a seleção de features mais relevantes na modelagem. Complementarmente, foram realizados testes estatísticos para verificar diferenças significativas entre grupos – utilizando as variáveis categóricas de regionalização –, como análise de variância (ANOVA) e testes de *post hoc* para comparar médias e medianas entre macrorregiões e unidades da federação.

A partir dessa análise preliminar, buscou-se obter uma compreensão mais aprofundada dos dados e garantir que as decisões tomadas nas etapas subsequentes fossem embasadas em uma avaliação robusta e criteriosa das informações disponíveis.

1.3.9 Aprendizado de Máquina: supervisionado e não-supervisionado

A clusterização, uma técnica de aprendizado não supervisionado, foi empregada para identificar padrões e agrupar municípios brasileiros com base em suas características territoriais, demográficas e de uso da terra. Diferentemente dos modelos supervisionados, a clusterização não requer rótulos previamente definidos, permitindo a descoberta de estruturas ocultas nos dados e a segmentação dos municípios de forma empírica. Essa abordagem é especialmente útil para a análise exploratória e para a formulação de hipóteses sobre possíveis tipologias de municípios (Maia; Quadros, 2009).

Durante a execução do trabalho, foram utilizadas técnicas de agrupamento para identificar possíveis novas regiões de acordo com as características coletadas e/ou geradas dos municípios, proveniente da engenharia de funcionalidades.

Os resultados obtidos foram analisados comparando as características médias de cada cluster, permitindo a identificação de padrões comuns entre os municípios agrupados. Essa análise possibilitou a inferência de possíveis perfis municipais, tais como grupos que compartilham características ambientais semelhantes, entre elas: padrões relacionados ao crescimento ou decréscimo de áreas ocupadas por diferentes classes de ocupação de terras (mosaico da paisagem) e as variações populacionais semelhantes entre municípios.

Na etapa de classificação, foi utilizada uma abordagem de aprendizado supervisionado para modelar a relação entre as variáveis independentes e as variáveis dependentes, a fim de prever comportamentos ou tendências em função das características territoriais e demográficas dos municípios. O processo de seleção e treinamento dos modelos envolveu a divisão dos dados em conjuntos de treino e teste, utilizando uma abordagem de validação cruzada para evitar o *overfitting* e garantir que os modelos pudessem ser avaliados de forma robusta (Berrar, 2019).

1.3.10 Explainable Artificial Intelligence (XAI) e Feature Importance Analysis

Por fim, a pesquisa incorporou técnicas de *Explainable Artificial Intelligence* (XAI), com o objetivo de interpretar os modelos de aprendizado de máquina aplicados e garantir maior transparência e compreensibilidade dos resultados obtidos. A interpretabilidade dos modelos é especialmente relevante no contexto de algoritmos considerados como “caixa-preta” (*black-box models*), termo utilizado para descrever técnicas cujos mecanismos internos de tomada de decisão são complexos ou pouco acessíveis à interpretação humana direta (Alves; Andrade, 2022). Modelos baseados em redes neurais profundas ou *gradient boosting* são exemplos típicos desse tipo.

Embora o *Random Forest* seja constituído por árvores de decisão — que individualmente são modelos transparentes —, o grande número de árvores envolvidas na floresta, aliado à forma como as decisões são agregadas, dificulta a interpretação direta e global do modelo. Assim, ele é frequentemente classificado como um modelo de interpretabilidade intermediária: mais compreensível do que redes neurais, mas menos transparente do que regressões lineares ou uma única árvore de decisão.

Para lidar com esse desafio, são empregadas técnicas de XAI, como o SHAP (*SHapley Additive exPlanations*), proposto por Lundberg e Lee (2017), que se baseia na Teoria dos Jogos para quantificar a contribuição individual de cada variável em cada predição. O SHAP permite não apenas compreender a direção e a magnitude do impacto de cada atributo, mas também comparar sua influência em diferentes agrupamentos de municípios.

Complementarmente, também é realizada uma análise de importância de atributos (*feature importance*) baseada na média das reduções de impureza ao longo das árvores, fornecendo um ranqueamento dos fatores que mais influenciam o comportamento do modelo. Com isso, a abordagem XAI se torna um recurso essencial para garantir a legibilidade dos resultados e ampliar sua utilidade na compreensão e caracterização dos municípios brasileiros sob múltiplas dimensões.

1.3.11 Softwares utilizados

Para a realização dos procedimentos metodológicos – excluído a parte relacionada a revisão bibliográfica –, foram utilizados majoritariamente o Google Colab com a linguagem de Programação Python e bibliotecas relacionadas ao processamento de aprendizado de máquina e elaboração de figuras, tais como:

- Pandas: Para manipulação e estruturação de dados em *Data Frames*, facilitando a limpeza, transformação e análise exploratória.
- NumPy: Para operações numéricas e manipulação eficiente de *arrays* multidimensionais.
- Scikit-learn: Para a aplicação de algoritmos de aprendizado de máquina, incluindo regressão, clusterização e análise de importância das variáveis.
- Matplotlib e Seaborn: Para a construção de visualizações gráficas que auxiliem na interpretação dos dados e resultados.

Outros softwares foram utilizados para a realização desse trabalho, incluindo:

- LibreOffice: para consultas e procedimentos simplificados em planilhas.
- Weka: para a aplicação de algoritmos de aprendizado de máquina.
- Jamovi: para execução de testes estatísticos.
- QGIS: Para a elaboração de mapas coropléticos.

A metodologia adotada nesta pesquisa seguiu uma abordagem estruturada para integrar e analisar dados territoriais, demográficos e ambientais dos municípios brasileiros. Inicialmente, foi realizada uma revisão bibliográfica para embasar teoricamente a seleção das variáveis e dos métodos analíticos. Em seguida, foram escolhidas e coletadas bases de dados relevantes, incluindo fontes como o IBGE e o MapBiomias, garantindo uma visão abrangente das características municipais. Após a coleta e armazenamento dos dados, foi conduzido um pré-processamento, que envolveu a limpeza, padronização e organização das informações. A etapa de engenharia de features permitiu a criação de novas variáveis derivadas, enriquecendo a base para análises mais robustas. A análise exploratória e descritiva foi aplicada para compreender a distribuição dos dados, detectar padrões iniciais e identificar possíveis inconsistências. No campo da inteligência artificial, foram adotadas abordagens supervisionadas, por meio de modelos de classificação, para prever relações entre variáveis, e não supervisionadas, utilizando clusterização para identificar grupos municipais com características semelhantes. Além disso, técnicas de *Explainable AI* (XAI) foram aplicadas para interpretar os resultados e entender a importância das variáveis na modelagem.

Como descrito acima, a metodologia seguiu um fluxo sistemático (Figura 2) que combina métodos estatísticos e técnicas de IA para explorar as dinâmicas municipais, em aspectos multidimensionais, oferecendo uma análise abrangente e interpretável do território brasileiro.

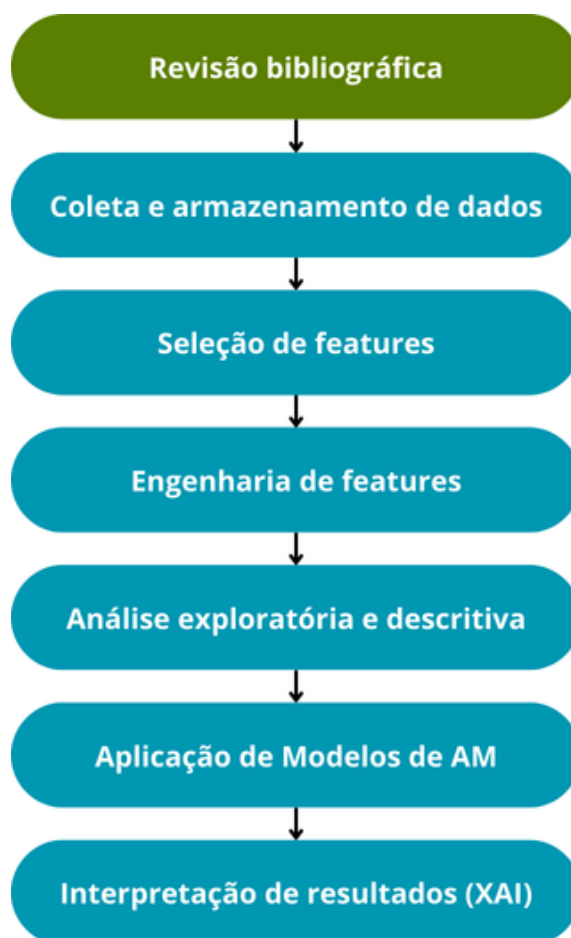


Figura 2. Pipeline metodológico. Elaboração: o autor.

1.4 Estrutura da Dissertação

A dissertação está organizada em capítulos que abordam desde a fundamentação teórica e institucional do município até a aplicação de metodologias para análise de suas dinâmicas territoriais, demográficas e ambientais. A estrutura foi elaborada de forma a garantir uma progressão lógica entre os temas.

O Capítulo 2, intitulado “O Município como Unidade de Análise: Definições e Dimensões”, estabelece o município como a unidade central de investigação. Inicialmente, discute-se a definição institucional do município no Brasil, considerando sua evolução histórica e o papel das mudanças legislativas na configuração municipal. Em seguida, são abordadas as características territoriais dos municípios brasileiros, incluindo variações regionais em sua extensão e configuração espacial. Também são exploradas as dinâmicas demográficas municipais, analisando padrões de crescimento, declínio populacional e classificação dos municípios segundo critérios demográficos. Posteriormente, o capítulo trata do uso e cobertura da terra nos municípios, destacando transformações ambientais e padrões espaciais associados. Por fim, são discutidas as estratificações e/ou tipologias existentes e a necessidade de novas abordagens metodológicas para uma análise mais refinada das especificidades municipais.

O Capítulo 3, intitulado “Aplicação de Técnicas de IA/ML para Análise Municipal”, investiga o papel das técnicas computacionais nos estudos relacionados à integração de bases de dados e aplicações. São exploradas as potencialidades do aprendizado de máquina na análise espaço-temporal, evidenciando suas aplicações no estudo de padrões municipais como expansão da mancha urbana e deflorestamento. Além disso, são discutidas as limitações e desafios do uso de IA para interpretação desses dados, considerando aspectos como disponibilidade de dados, vieses algorítmicos e dificuldades na explicabilidade dos modelos.

Em “Considerações Finais”, são apresentados os resultados mais relevantes da pesquisa e suas implicações. Inicialmente, são sintetizados os padrões e dinâmicas municipais identificados a partir da análise integrada. Por fim, são feitas reflexões sobre os achados da pesquisa.

2 O MUNICÍPIO COMO UNIDADE DE ANÁLISE: DEFINIÇÕES E DIMENSÕES

Neste capítulo, buscou-se compreender os municípios brasileiros a partir de diferentes perspectivas, explorando suas definições institucionais, aspectos territoriais, dinâmicas demográficas e ambientais. Inicialmente, foi apresentada a definição institucional dos municípios no Brasil, abordando sua formação histórica e seu papel dentro da federação. Em seguida, foram discutidas as características territoriais dos municípios brasileiros, com ênfase na diversidade de tamanhos, formas e condições geográficas que influenciam sua governança e desenvolvimento.

2.1 A definição institucional de município no Brasil

Os municípios desempenham um papel central na administração pública e na formulação de políticas territoriais, sociais e ambientais no Brasil. Como unidade administrativa fundamental, e de menor nível, eles são responsáveis por uma série de decisões que impactam diretamente a vida da população e o uso do território (Arretche, 2004; Arretche, 2010). No entanto, apesar de sua relevância, os municípios apresentam grande diversidade em termos de características territoriais, dinâmicas populacionais e padrões de uso e cobertura da terra. Essa heterogeneidade torna desafiadora a formulação de análises comparativas e modelos preditivos que considerem de forma integrada seus múltiplos aspectos (Sposito, 2024).

Os municípios constituem as unidades fundamentais e de menor abrangência da organização político-administrativa do Estado brasileiro, sendo dotados de personalidade jurídica e autonomia. Fundamentados na Constituição Federal de 1988, Capítulo 1, Artigo 18, os municípios são concebidos não apenas como divisões territoriais, mas como entes políticos que exercem funções essenciais para a promoção do desenvolvimento local e a efetivação da cidadania (Brasil, 1988).

2.2 Características territoriais dos municípios brasileiros, o n-município.

A análise das municipalidades ajuda a compreender a estrutura da política administrativa do território. Essa fragmentação do espaço em subespaços, é originada por diversas causas, entre elas: a ineficiência da esfera municipal com as vilas, a grande extensão territorial do município e aumento da população; levando-as ao processo de emancipação (Bremaeker, 1993). Essas diversas emancipações resultam na emergência de novas relações socioespaciais.

Assim como exposto anteriormente, a Constituição de 1988 redefiniu o papel dos municípios no Brasil, conferindo-lhes autonomia política, administrativa e financeira, o que impulsionou a criação de novos municípios. Através de uma breve análise histórica, notou-se que o processo de municipalização foi especialmente intenso até a década de 1960, havendo um bloqueio a partir de 1964 (regime militar) com uma intensa centralização do poder na esfera federal. Com a superação do regime autoritário, houve um movimento para a descentralização política-administrativa e a facilitação dos critérios para emancipação municipal (Arretche, 2010), havendo um crescimento diferencial especialmente em estados do Norte, Sul e Centro-Oeste, onde havia forte demanda por acesso a serviços públicos locais, e um discurso institucional para a interiorização do País. Com esse crescimento acelerado de emancipações, alterou-se as dinâmicas de poderes e econômicas do País, culminando na Emenda Constitucional nº 15/1996, a que dificultou os critérios para a criação de novos municípios, resultando em uma “estabilidade territorial de emancipações” (Gráfico 1a e 1b).

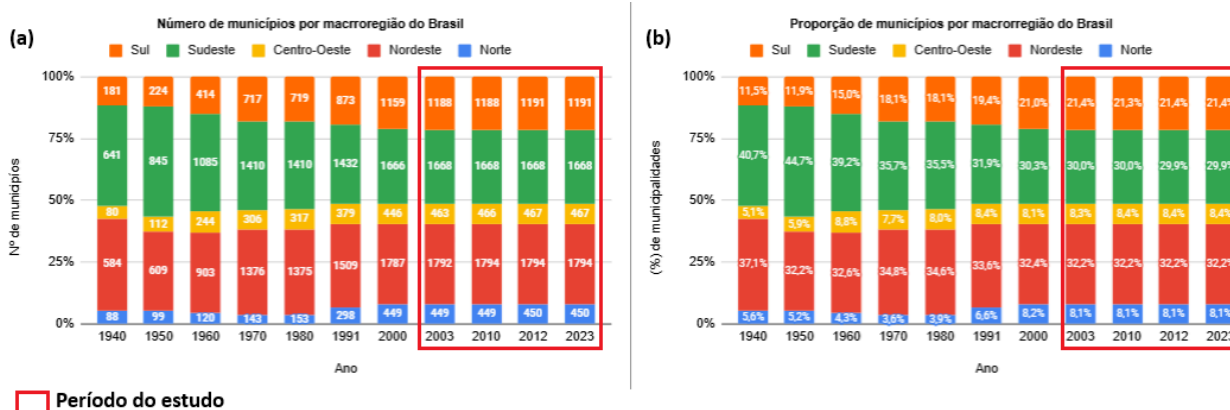


Gráfico 1. Gráficos de quantidade de municípios e proporção de municípios por grandes regiões do Brasil.

Elaboração: o autor. Fonte: IBGE, 2023.

O crescimento territorial desigual entre as grandes regiões do Brasil, observado sob diversas dimensões — em especial no contexto da fragmentação territorial decorrente das emancipações municipais —, pode ser compreendido à luz dos vetores modernizantes articulados por forças hegemônicas. Tais vetores, conforme discutido por Santos e Silveira (2001) e Santos (2005), operam no território promovendo uma espacialização diferencial, seletivamente o acesso a bens, serviços e infraestrutura, intensificando processos de centralização e periferação. Nesse sentido, a multiplicação de municípios, especialmente nas regiões Norte e Sul, reflete não apenas demandas locais por autonomia e serviços públicos, mas também as estratégias mais amplas de ordenamento territorial, implementação de sistemas de engenharias oriundos da difusão técnica-científica desigual e a expansão do alcance do Estado.

Na macrorregião Nordeste, a criação de novos municípios foi impulsionada principalmente pela necessidade de descentralização dos serviços públicos e pela busca por maior representatividade política. Muitos distritos, antes marginalizados administrativamente, viram na emancipação uma oportunidade de acesso direto a repasses federais e estaduais. Contudo, a viabilidade econômica desses novos municípios frequentemente foi questionada, já que muitas dessas unidades administrativas tinham baixa arrecadação própria e dependiam fortemente do Fundo de Participação dos Municípios (FPM) (Bremaeker, 1993).

Na macrorregião Norte, a expansão municipal ocorreu de forma significativa, especialmente devido à necessidade de ocupação territorial e administração de áreas remotas. Com grandes extensões territoriais e baixa densidade populacional, estados como Pará e Amazonas enfrentavam dificuldades na prestação de serviços básicos em localidades isoladas. A emancipação foi vista como uma solução para essa problemática, permitindo maior proximidade entre a administração municipal e os cidadãos (Paloni, 2008). No entanto, a criação de municípios na região também esteve atrelada à expansão da fronteira agrícola e a interesses políticos locais, resultando, em alguns casos, em municípios com baixa capacidade administrativa e pouca infraestrutura (Becker, 1996).

A macrorregião Centro-Oeste também passou por um processo expressivo de criação de novos municípios, mas com características distintas. A dinâmica de expansão urbana e agropecuária, especialmente no Mato Grosso e Goiás, contribuiu para a emancipação de várias localidades. A valorização da atividade agrícola e a necessidade de gestão descentralizada foram fatores que impulsionaram essa fragmentação territorial. Diferentemente do Norte e Nordeste, muitos municípios criados nessa região apresentavam maior viabilidade econômica, pois estavam inseridos em áreas de crescimento agroindustrial, com maior arrecadação tributária e infraestrutura básica já estabelecida (Magalhães, 2007).

Na macrorregião Sudeste, o processo de emancipação foi mais contido em comparação com outras regiões. Com uma rede urbana mais consolidada e maior concentração de recursos, a demanda por novos municípios foi menor (Souza, 2015). A descentralização ocorreu de forma mais seletiva, geralmente motivada por pressões de grupos locais que buscavam maior autonomia administrativa. Em estados como Minas Gerais, que já possuía um grande número de municípios antes de 1988, houve um aumento expressivo, mas sem a mesma intensidade observada no Norte e Nordeste. Em São Paulo, Espírito Santo e Rio de Janeiro, a criação de novos municípios foi mais limitada devido a fatores econômicos e critérios mais rígidos estabelecidos pelos estados,

uma vez que acrescido o número de municípios a distribuição de recursos tende a diminuir entre os entes do Estado (Siqueira, 2003).

Por fim, na macrorregião Sul, o processo de emancipação municipal foi bastante significativo, especialmente no Rio Grande do Sul e no Paraná. Movimentos locais defendiam a criação de novos municípios com o argumento da melhoria na gestão pública e na oferta de serviços essenciais. Muitas das novas unidades administrativas na região apresentavam estrutura econômica baseada na agroindústria e em pequenas e médias empresas, o que favoreceu sua sustentabilidade financeira. No entanto, a fragmentação excessiva também gerou desafios, como a dificuldade de manter serviços públicos com eficiência em municípios de pequeno porte e baixa arrecadação, gerando a “insustentabilidade municipal” (Souza, 2015).

Entre 1940 e 2023, o número de municípios brasileiros passou por variações significativas, cujas dinâmicas expressam processos regionais distintos em cada macrorregião (Gráfico 2). No período entre 1940 e 1960, observou-se um crescimento moderado no número de municípios, com maior concentração no Sudeste e no Sul, refletindo o avanço da urbanização e da organização administrativa regional. Durante o regime militar (1964–1985), houve um bloqueio institucional na criação de novos municípios, reduzindo o ritmo de crescimento em todo o país. Com a redemocratização e, especialmente, após a promulgação da Constituição de 1988, o número de municípios aumentou de forma acelerada, sobretudo entre os censos de 1980 e 2000. As regiões Norte, Centro-Oeste e Sul apresentaram os maiores crescimentos percentuais no período, impulsionadas por políticas de interiorização, demandas por serviços públicos locais e reorganização administrativa de áreas rurais.

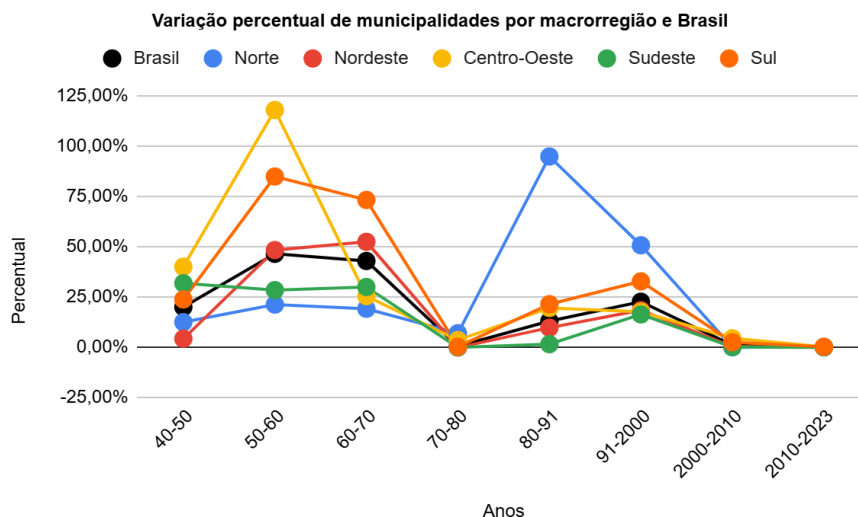


Gráfico 2. Gráfico com a variação percentual de municípios em períodos intercensitários. Elaboração: o autor. Fonte: IBGE, 2023.

Consequentemente, a maioria dos municípios brasileiros manteve suas delimitações territoriais estáveis, com exceção de alguns casos isolados de desmembramento e ajustes em seus limites. No entanto, a pouca variação no número de municípios não impediu que as transformações internas, como mudanças no uso e cobertura da terra, continuassem a ocorrer, refletindo as especificidades e os desafios enfrentados por cada unidade territorial ao longo do período.

Dessa forma, mesmo diante de um cenário de estabilidade na criação de novos municípios desde o início dos anos 2000, as dinâmicas territoriais permanecem ativas e heterogêneas, expressando-se por meio de transformações internas que vão além da simples redefinição de limites político-administrativos. As mudanças no uso e cobertura da terra, os fluxos populacionais e a reorganização funcional dos espaços municipais evidenciam que a extensão territorial, embora juridicamente estática em muitos casos, continua sendo palco de reconfigurações socioespaciais relevantes. Nesse sentido, torna-se essencial compreender as dinâmicas de extensão territorial dos municípios e os padrões de classificação que emergem a partir dessas transformações, revelando tendências de expansão, retração ou reestruturação espacial.

2.3 Dinâmicas de extensão territorial e seus padrões de classificação

Para aprofundar a compreensão das diferenças na extensão territorial dos municípios brasileiros, foi realizada uma análise descritiva considerando a distribuição das áreas municipais por macrorregião e por unidade da federação respectivamente (Apêndice 1 e 2). Essa abordagem

permite identificar características regionais e contrastes significativos entre os municípios, ressaltando as particularidades de cada contexto geográfico. A separação por macrorregião evidencia as desigualdades estruturais na organização do território, como a predominância de municípios extensos no Norte e no Centro-Oeste, em oposição aos municípios menores e mais fragmentados do Sudeste e do Nordeste. Ao utilizar medidas estatísticas descritivas, como mediana, quartis e dispersão dos dados, essa avaliação busca demonstrar a heterogeneidade territorial do país.

Para ilustrar graficamente a discrepância no tamanho das municipalidades brasileiras, foram criados dois mapas (Figura 3). Esse método de visualização permite destacar o tamanho dos municípios, evidenciando a disparidade entre as diferentes regiões do país. O mapa à esquerda (Figura 3a) teve suas duas classes delimitadas pela mediana da extensão territorial nacional, em vez da média, minimizando o impacto de valores extremos como os grandes municípios do Norte. Ao exibir as áreas municipais em função dessa medida central, o mapa permitiu identificar claramente os contrastes de tamanho, desde os pequenos municípios, com menos de 418 km², até os vastos, que cobrem milhares de quilômetros quadrados. O mapa à direita (Figura 3b) orienta-se pelo estudo de Bremaeker (1993), possibilitando a classificação de modo mais gradiente, com classes menos amplas, agregando uma visualização facilitada da relação entre densidade municipal e território nacional.




Figura 3. Mapas de extensão territorial gerados a partir de diferentes classes de tamanho de extensão.

Elaboração: o autor. Fonte: IBGE, 2023; Bremaeker, 1993.

A distribuição dos municípios brasileiros reflete um padrão espacial marcadamente influenciado por fatores históricos e socioeconômicos (Santos, 2005). No litoral, observa-se uma alta densidade municipal, com municípios geralmente menores em área e dispostos de forma mais compacta. Em contraste, o interior do país, especialmente nas regiões Norte e Centro-Oeste, apresenta uma densidade municipal significativamente menor, com municípios de grandes extensões territoriais e baixa ocupação populacional relativa. Esse padrão decorre, em grande parte, da ocupação tardia dessas áreas, muitas vezes voltada para atividades agropecuárias extensivas (Centro-Oeste) e exploração de recursos naturais (Norte) (Santos, 2005). Além disso, a menor densidade de infraestrutura e a vasta extensão territorial dificultam a subdivisão municipal, resultando em municípios que, em alguns casos, ultrapassam dezenas de milhares de quilômetros quadrados.

A distinção por diferentes tipologias relacionadas à extensão territorial ajuda a compreender melhor a heterogeneidade e as dificuldades no planejamento e na gestão territorial no contexto brasileiro.

A análise da extensão territorial dos municípios brasileiros por macrorregião (Figura 4) foi realizada com o intuito de identificar diferenças estatísticas na distribuição das áreas municipais ao longo do tempo (2003, 2012 e 2023) e a variação proporcional de extensão de território para três períodos (2003 a 2012, 2012 a 2023, 2003 a 2023). Para isso, utilizou-se o teste de Kruskal-Wallis, adequado para comparar distribuições não normais entre múltiplos grupos (Mckight; Najab, 2010), e, posteriormente, o teste de Dwass-Steel-Critchlow-Fligner (DSCF) para comparações múltiplas entre pares de macrorregiões. O valor de $p < 0.05$, indica uma forte evidência estatística para rejeitar a hipótese nula, que assume que não há diferença significativa entre as distribuições das extensões territoriais dos municípios nas diferentes macrorregiões.

Os resultados do teste de Kruskal-Wallis apontam que, para todos os anos analisados (2003, 2012 e 2023), há diferenças estatisticamente significativas entre as macrorregiões ($p < 0.001$). Isso indica que a extensão territorial dos municípios não segue uma distribuição homogênea entre as diferentes regiões do país. Enquanto, as variações proporcionais do território (entre os períodos analisados) apresentam valores maiores que $p > 0.05$ aceitando a hipótese alternativa, onde não há diferença significativa entre os grupos de macrorregiões, esse resultado de maneira geral pode ser associado a um grande número de municípios que não tiveram mudanças significativas em relação a suas áreas totais iniciais.

Kruskal-Wallis			
	χ^2	gl	p
AREA_2003_KM2	1268.06	4	< .001
AREA_2012_KM2	1276.78	4	< .001
AREA_2023_KM2	1281.33	4	< .001
PROP_VAR_2003_2012	4.54	4	0.338
PROP_VAR_2012_2023	2.69	4	0.611
PROP_VAR_2003_2023	2.71	4	0.607

Figura 4. Testes de Kruskal-Wallis para variáveis de área nas Macrorregiões. Elaboração: o autor. Fonte: IBGE, 2023.

Para identificar quais macrorregiões diferem entre si, o teste pós-hoc DSCF foi aplicado. Os resultados revelaram padrões consistentes ao longo dos anos (Figura 5). O valor de W representa a estatística de teste associada à comparação entre dois grupos. Ele indica a magnitude da diferença entre as distribuições das amostras comparadas, levando em conta a dispersão dos dados e o número de observações em cada grupo. Para as variáveis relacionadas à variação de área do município, os resultados mostram-se diferentes, apresentando uma diferença significativa somente entre Norte e Sul para o período de 2003 a 2012 (Figura 7, em destaque). Demonstra-se

que na escala de macrorregiões, o País assume características territoriais heterogêneas pelos aspectos de extensão territorial.

Comparações múltiplas - AREA_2003_KM2				Comparações múltiplas - AREA_2012_KM2				Comparações múltiplas - AREA_2023_KM2			
		W	p			W	p			W	p
Norte	Nordeste	-33.16	< .001	Norte	Nordeste	-33.23	< .001	Norte	Nordeste	-33.15	< .001
Norte	Sudeste	-37.36	< .001	Norte	Sudeste	-37.41	< .001	Norte	Sudeste	-37.33	< .001
Norte	Sul	-37.32	< .001	Norte	Sul	-37.36	< .001	Norte	Sul	-37.34	< .001
Norte	Centro-oeste	-9.10	< .001	Norte	Centro-oeste	-9.11	< .001	Norte	Centro-oeste	-9.02	< .001
Nordeste	Sudeste	-10.65	< .001	Nordeste	Sudeste	-10.74	< .001	Nordeste	Sudeste	-10.97	< .001
Nordeste	Sul	-16.19	< .001	Nordeste	Sul	-16.22	< .001	Nordeste	Sul	-16.59	< .001
Nordeste	Centro-oeste	25.04	< .001	Nordeste	Centro-oeste	25.25	< .001	Nordeste	Centro-oeste	25.26	< .001
Sudeste	Sul	-7.64	< .001	Sudeste	Sul	-7.59	< .001	Sudeste	Sul	-7.78	< .001
Sudeste	Centro-oeste	30.42	< .001	Sudeste	Centro-oeste	30.64	< .001	Sudeste	Centro-oeste	30.69	< .001
Sul	Centro-oeste	31.53	< .001	Sul	Centro-oeste	31.69	< .001	Sul	Centro-oeste	31.80	< .001
Comparações múltiplas - PROP_VAR_2003_2012				Comparações múltiplas - PROP_VAR_2012_2023				Comparações múltiplas - PROP_VAR_2003_2023			
		W	p			W	p			W	p
Norte	Nordeste	-0.1828	1.000	Norte	Nordeste	1.912	0.659	Norte	Nordeste	1.267	0.899
Norte	Sudeste	0.2749	1.000	Norte	Sudeste	0.666	0.990	Norte	Sudeste	1.039	0.949
Norte	Sul	-5.8208	< .001	Norte	Sul	0.736	0.985	Norte	Sul	-0.163	1.000
Norte	Centro-oeste	-1.7131	0.745	Norte	Centro-oeste	1.427	0.852	Norte	Centro-oeste	1.024	0.951
Nordeste	Sudeste	0.6626	0.990	Nordeste	Sudeste	-1.341	0.878	Nordeste	Sudeste	-0.713	0.987
Nordeste	Sul	-2.0850	0.579	Nordeste	Sul	-1.592	0.793	Nordeste	Sul	-1.702	0.750
Nordeste	Centro-oeste	-0.4272	0.998	Nordeste	Centro-oeste	-0.385	0.999	Nordeste	Centro-oeste	-0.330	0.999
Sudeste	Sul	-1.5120	0.823	Sudeste	Sul	0.323	0.999	Sudeste	Sul	-1.819	0.700
Sudeste	Centro-oeste	0.0453	1.000	Sudeste	Centro-oeste	0.943	0.964	Sudeste	Centro-oeste	0.517	0.996
Sul	Centro-oeste	-0.3179	0.999	Sul	Centro-oeste	1.309	0.887	Sul	Centro-oeste	1.480	0.834

Figura 5. Teste de Dwass-Steel-Critchlow-Fligner com variáveis de área para macrorregiões. Elaboração: o autor. Fonte: IBGE, 2023.

A variação proporcional da área em relação à extensão territorial permite analisar as transformações nos limites municipais, considerando a representatividade das mudanças dentro da área total de cada município. Esse indicador facilita a comparação entre diferentes localidades, independentemente de seu tamanho absoluto, evidenciando quais regiões apresentam maior dinâmica territorial.

Destacam-se, por esse indicador, os municípios situados ao longo da fronteira terrestre das regiões Norte e Centro-Oeste (Figura 6), onde alguns registraram acréscimos de até 2,5 vezes sua extensão territorial original, enquanto outros sofreram reduções significativas, chegando a perder aproximadamente metade de sua área inicial.




Figura 6. Mapas coropléticos de representação da variação proporcional de área municipal total, reduzida ou acrescentada por três períodos de tempo (2003-2012, 2012-2023 e 2003-2023). Elaboração: o autor. Fonte: IBGE, 2023.

A análise da evolução da área municipal ao longo do tempo nos estados brasileiros revelou padrões distintos de variação territorial que podem estar relacionados a processos administrativos, redefinição de limites municipais e possíveis erros de medição ao longo dos anos (Gráfico 3). Observou-se que, na maioria dos estados do Brasil (e. g. São Paulo e Rio Grande do Sul), a área de determinados municípios manteve-se estável ao longo do período analisado, enquanto em outros há variações mais perceptíveis (principalmente quando relacionadas a grandes mudanças), estas possivelmente associadas a correções cartográficas ou mudanças nos critérios de delimitação territorial operacionalizados e divulgados pelo IBGE (IBGE, 2023f). Essas variações podem ser mais evidentes em estados com histórico recente de reorganização administrativa, como aqueles que passaram por desmembramentos ou ajustes nos limites municipais no período entre 2003 e 2012. Quando realizada a análise das áreas por unidades federativas (Gráfico 4), notou-se que em algumas regiões as linhas moldam curvas acentuadas (e. g. Paraíba e Pernambuco), revelando grandes modificações anuais, em alguns momentos acontecem junções nas séries, demonstrando a totalidade do território sendo fragmentada e ajustada a novas legislações e normativas.

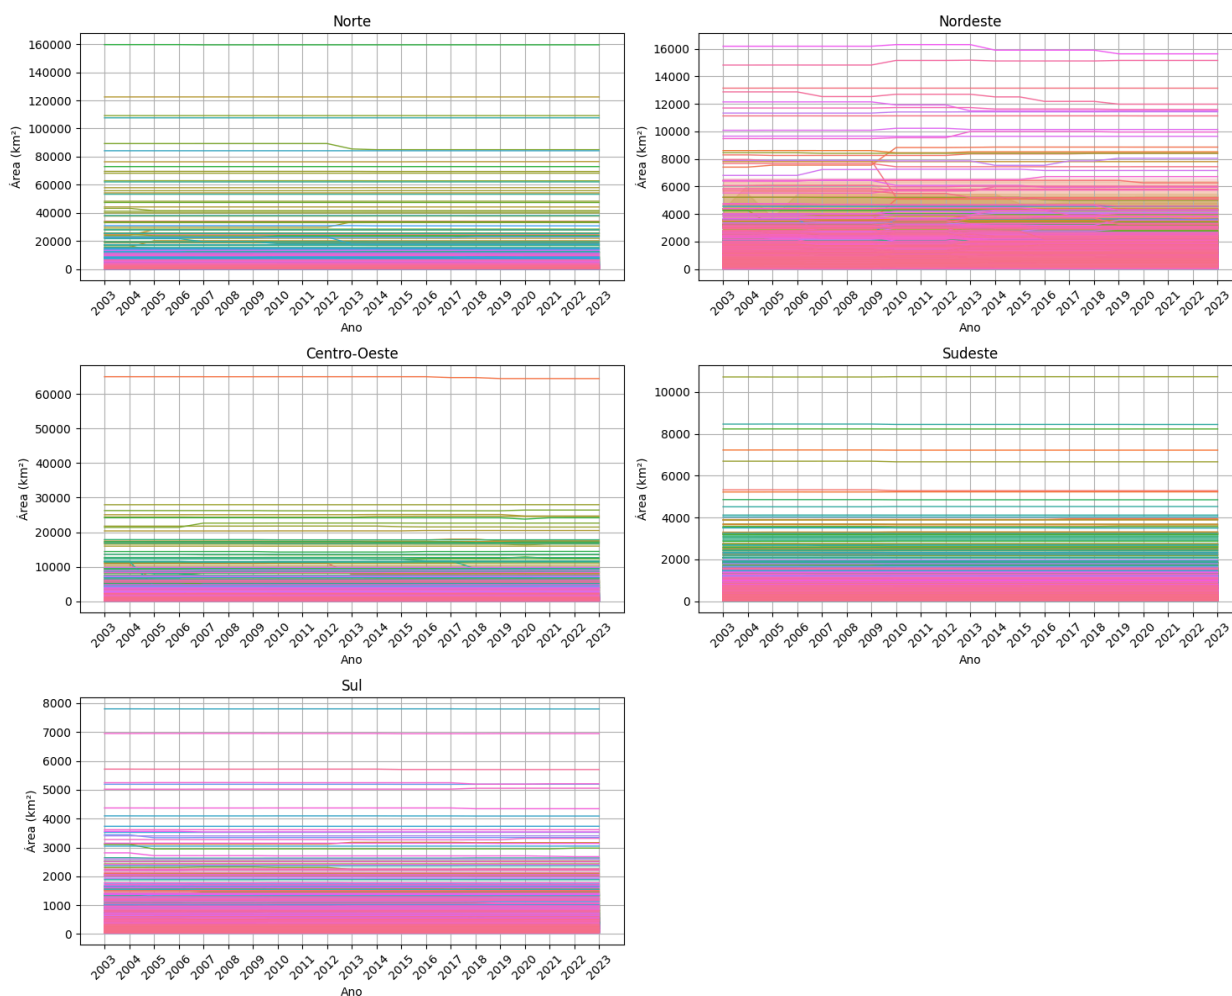


Gráfico 3. Séries temporais municipais para variável extensão territorial de 2003 a 2023 na abrangência das grandes regiões. Elaboração: o autor. Fonte: IBGE, 2023.



Gráfico 4. Séries temporais municipais para variável extensão territorial de 2003 a 2023 na abrangência das Unidades da Federação (UF). Elaboração: o autor. Fonte: IBGE, 2023.

Além disso, a dispersão das curvas municipais dentro de cada Unidade da Federação evidencia a diversidade de tamanhos territoriais entre os municípios, refletindo características geográficas e históricas da ocupação do território brasileiro. Em estados da região Norte, por exemplo, a presença de municípios com extensões territoriais significativamente maiores é notável, enquanto nas regiões Sul e Sudeste predominam municípios com áreas menores. Esse contraste de extensões territoriais entre diferentes regiões sugere diferenças estruturais na formação dos municípios, influenciadas por fatores como densidade populacional, padrões de colonização e políticas de desenvolvimento regional.

A fim de encontrar padrões entre as variáveis analisadas é construído uma matriz de correlações. A matriz de correlação mostra o grau de associação entre diferentes variáveis, variando de -1 a 1. Valores próximos de 1 indicam uma correlação positiva forte, ou seja, quando uma variável aumenta, a outra também tende a aumentar. Valores próximos de -1 indicam uma correlação negativa forte, significando que quando uma variável cresce, a outra tende a diminuir. Já valores próximos de 0 indicam uma relação fraca ou inexistente entre as variáveis.

Na interpretação, é importante observar a intensidade e o sinal das correlações, além de considerar o contexto dos dados. Correlações elevadas sugerem relações consistentes ao longo do tempo ou entre diferentes medidas, enquanto correlações baixas indicam maior variabilidade ou ausência de padrões claros. Essa análise permitirá uma melhor modelagem de dados para operacionalização de modelos de aprendizado de máquina no próximo capítulo.

A análise das correlações (Gráfico 5) entre as variáveis de área territorial dos municípios brasileiros e suas respectivas variações ao longo do tempo revela padrões consistentes e esperados. Observou-se uma forte correlação positiva entre as áreas municipais nos anos de 2003, 2012 e 2023, indicando estabilidade na extensão territorial da maioria dos municípios ao longo das duas décadas analisadas. Essa relação era esperada, uma vez que mudanças territoriais municipais no Brasil para o período analisado são relativamente raras e ocorrem principalmente por ajustes de limites administrativos. No entanto, a presença de algumas variações indica que certos municípios passaram por processos de redefinição de suas áreas no período estudado.

As variáveis que representam a variação absoluta da área territorial em diferentes períodos mostram correlações moderadas a altas entre si, o que sugere que municípios que tiveram mudanças significativas em um período (2003-2012) tendem a continuar apresentando modificações territoriais no período seguinte (2012-2023). Essa continuidade pode estar relacionada a disputas territoriais, redefinição de limites municipais e reorganizações administrativas locais.

Por outro lado, as proporções de variação territorial em relação à área original dos municípios apresentam padrões distintos. Municípios menores, ao sofrerem alterações territoriais, tendem a apresentar variações proporcionais mais expressivas, o que justifica a correlação mais fraca dessas variáveis com a área total. Já as correlações entre as proporções de variação ao longo dos diferentes períodos indicam que municípios que tiveram uma mudança proporcionalmente significativa em uma década também são mais propensos a passar por novas alterações no período seguinte.




Gráfico 5. Matriz de correlação entre variáveis da dimensão territorial. Elaboração: o autor.

Dessa forma, a análise das características territoriais dos municípios brasileiros evidencia a diversidade e a complexidade da organização espacial no país. o território não pode ser compreendido apenas como um dado físico ou administrativo; ele é, antes de tudo, uma construção histórica e social, cuja essência está na relação dialética entre forma e conteúdo (Santos, 2002). A forma diz respeito à materialidade do território — sua extensão, divisões políticas, infraestrutura, rede urbana — enquanto o conteúdo representa os processos sociais, econômicos e ambientais que se manifestam nesse espaço. Dentro dessa lógica, as dinâmicas demográficas (como crescimento populacional e urbanização) e os padrões de uso e cobertura da terra (expansão agrícola, desmatamento, recuperação de vegetação, etc.) devem ser compreendidos como expressões do conteúdo territorial. Essas dimensões traduzem como os diferentes grupos sociais se apropriam e transformam o território, imprimindo nele suas lógicas e

interesses. Assim, ao considerar o município como unidade de análise, é fundamental entendê-lo como um recorte onde a forma territorial limita e condiciona, mas não determina por si só, os conteúdos que nele se manifestam — sendo necessário, portanto, analisá-los em sua interdependência.

2.3. Dinâmicas demográficas municipais e seus padrões de classificação

Para esse tópico, foi feita a utilização de estimativas populacionais anuais, combinadas com os dados do Censo Demográfico, permitindo uma análise mais ampla das dinâmicas populacionais ao longo do tempo, possibilitando a identificação de padrões estatisticamente significativos entre as Unidades da Federação e as Macrorregiões. Essas abordagens são fundamentais para iniciar a exploração de dados ligados à distribuição e padrões associados à população. Além disso, a análise de tendências populacionais ao longo de sucessivos anos pode permitir avaliar correlações de processos como incremento da malha urbana, deflorestamento e avanço da agropecuária.

Ao contrário da extensão territorial, a categorização dos municípios com base no número absoluto de habitantes é amplamente utilizada por instituições governamentais, pesquisadores e planejadores urbanos para segmentar e analisar dinâmicas populacionais. Essa abordagem permite simplificar – como preceito analítico por essência – a compreensão da estrutura municipal e facilitar a formulação de relatórios orientadores de políticas públicas direcionadas. No entanto, sua aplicação apresenta desafios significativos, tanto na padronização dos critérios quanto nas consequências diretas sobre o acesso a recursos e programas governamentais.

Diferentes órgãos e estudos estabelecem faixas populacionais distintas para definir pequenos, médios e grandes municípios, refletindo as necessidades e objetivos específicos de cada segmento (Tabela 3). Por exemplo, o Plano Nacional de Habitação (PlanHab) adota uma divisão simplificada em três categorias, enquanto o Atlas da Violência 2024 utiliza uma tipologia de 3 categorias, mas com faixas distintas de população, refletindo a preocupação com dinâmicas urbanas e segurança pública. Outras instituições, como o Fundo Nacional de Desenvolvimento da Educação (FNDE) e a pesquisa MUNICs, adotam segmentações mais detalhadas, permitindo um olhar mais refinado sobre as diferenças entre municípios pequenos e médios.

Fonte	Categorias	Faixas por População
Klering, Krueel e Stranz (2012)	10	Até 3000
		3001 a 10000
		10001 a 15000
		15001 a 25000
		25001 a 50000
		50001 a 100000
		100001 a 300000
		300001 a 500000
		500001 a 1000000
		Mais de 1000000
Gomes, Matos e Lobo (2020)	3	Até 50000
		50001 a 75000
		Mais de 750001
Plano Nacional de Habitação (PlanHab)	3	Até 20000
		20001 a 100000
		Mais de 100000
Atlas da Violência 2024	3	Até 100000
		100001 a 500000
		Mais de 500000
MUNICs (IBGE)	7	Até 5 000
		De 5 001 a 10 000
		De 10 001 a 20 000
		De 20 001 a 50 000
		De 50 001 a 100 000
		De 100 001 a 500 000
Fundo Nacional de Desenvolvimento da Educação (FNDE)	7	Mais de 500 000
		Até 5.000
		5.001 a 10.000
		10001 a 20.000
		20.001 a 50.000
		50.001 a 100.000
		100.001 a 200.000
		200.001 a 400.000
Mais de 400.000		
Confederação Nacional de Municípios (CNM)	3	Até 50000
		50.001 a 350.000
		Mais de 350.000

Tabela 3. Classificações municipais baseadas em população municipal. Elaboração: o autor.

Essa variedade de classificações pode levar a desafios na comparação de dados entre diferentes estudos e na elaboração de políticas públicas que sejam consistentes em nível nacional. Municípios que se enquadram em categorias diferentes dependendo do critério adotado podem receber tratamentos distintos na distribuição de recursos e investimentos, Lima (2023) aponta:

O Brasil não classifica ou normatiza seus Municípios de acordo com seu porte, colocando-os sob as mesmas exigências constitucionais e deveres legais, com o mesmo

princípio de distribuição de receitas, muito embora sua capacidade arrecadatória seja profundamente destoante.

Uma das fragilidades de categorizações fixas é referente aos limites das classes. Municípios com populações próximas aos limites estabelecidos, podem ser afetados por mudanças metodológicas ou variações demográficas mínimas e não serem considerados pertencentes à nova classe, o que pode influenciar sua elegibilidade para determinados programas. Esse cenário torna-se ainda mais grave, quando a geração dos dados é frequentemente interrompida ou tem granularidades diferenciais.

Outro ponto relevante é que a categorização por população, com números absolutos, ignora fatores qualitativos importantes, como a distribuição espacial dos habitantes, a densidade demográfica, a infraestrutura existente e as dinâmicas migratórias. Municípios pequenos podem enfrentar desafios tão complexos quanto grandes cidades, especialmente quando localizados em regiões isoladas ou em áreas de grande vulnerabilidade social (Sposito, 2024). Da mesma forma, municípios de grande porte podem apresentar desigualdades internas significativas, que não são capturadas apenas pelo número absoluto de habitantes, com a migração pendular nas regiões metropolitanas (Santana, *et al.*, 2024).

As séries temporais das populações municipais por macrorregiões e unidades da federação do Brasil (Gráficos 6 e 7), destacam a evolução populacional ao longo do tempo. Um padrão comum observado em todas as macrorregiões é o distanciamento das capitais do restante dos municípios, cujas populações se diferenciam significativamente. Esse fenômeno é particularmente evidente nas grandes regiões, que frequentemente apresentam picos populacionais consideráveis, devido a processos de urbanização acelerada e concentração de serviços e oportunidades. Outro padrão observado é a queda de população absoluta das capitais e cidades com as maiores populações entre os anos de 2021 e 2022². Esse padrão pode estar refletindo o ajuste entre as pesquisas de Estimativas Populacionais e a pesquisa do Censo 2022. Em contraste, os demais municípios, especialmente os de menor porte, exibem variações populacionais mais modestas, refletindo as dinâmicas regionais e as características socioeconômicas locais. A discrepância entre as capitais e os demais municípios ressalta o impacto das migrações internas, bem como as disparidades no desenvolvimento urbano e regional (Silva, 2015).

² Essa diminuição da população entre os anos de 2021 para 2022, pode estar associada a questões técnicas relacionadas a imputações de coleta do CENSO 2022, sendo necessário um aprofundamento. Outros percalços também foram constatados durante esses anos, podendo ser efeitos da pandemia e de cortes orçamentários na instituição responsável pela coleta, armazenamento e validação dos dados.

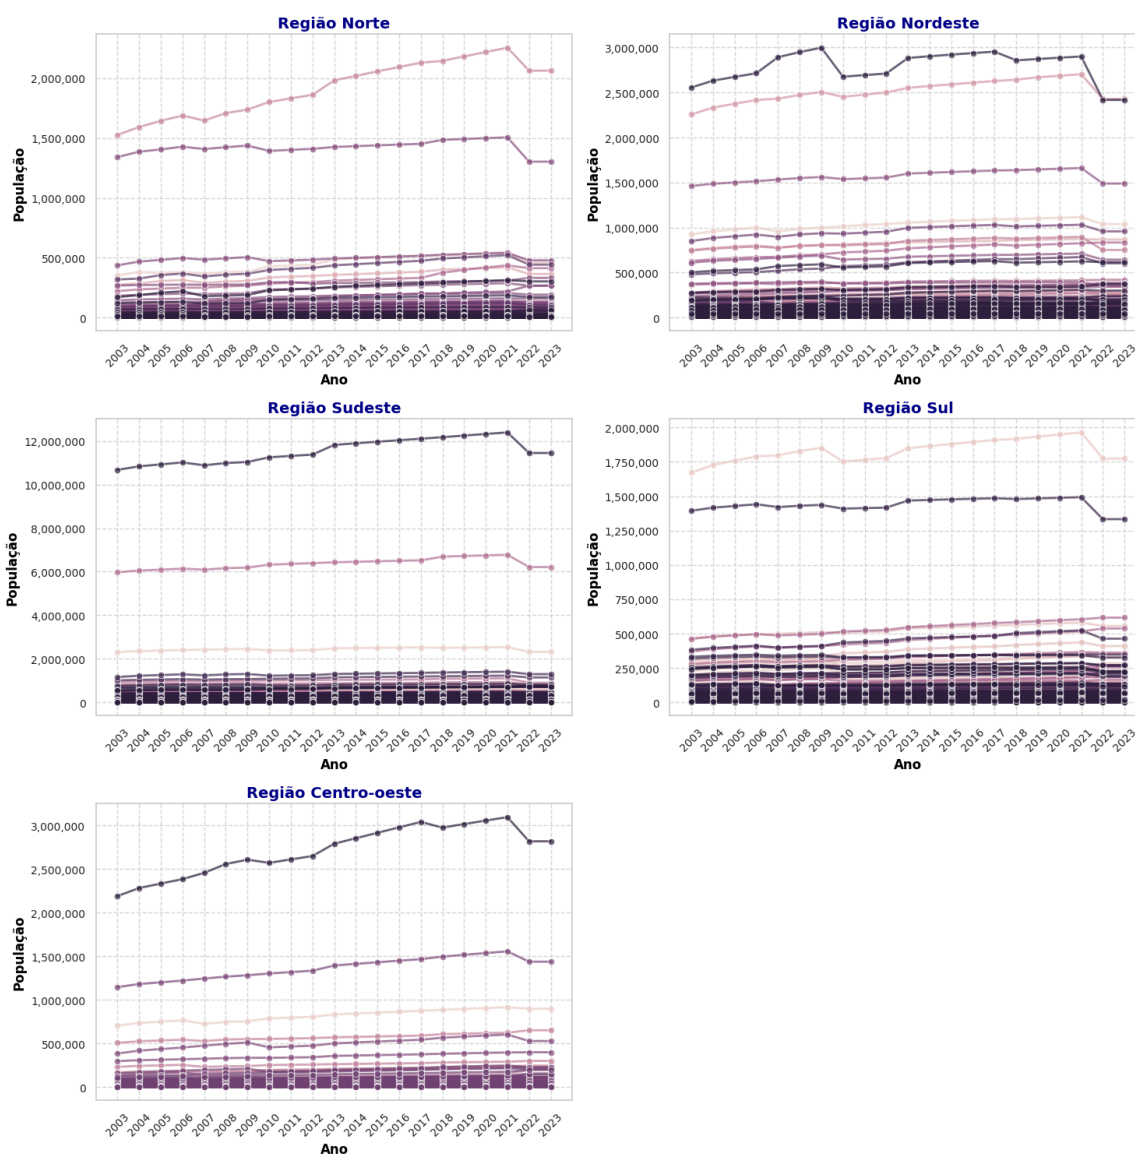


Gráfico 6. Séries temporais de populações municipais por macrorregiões do Brasil.

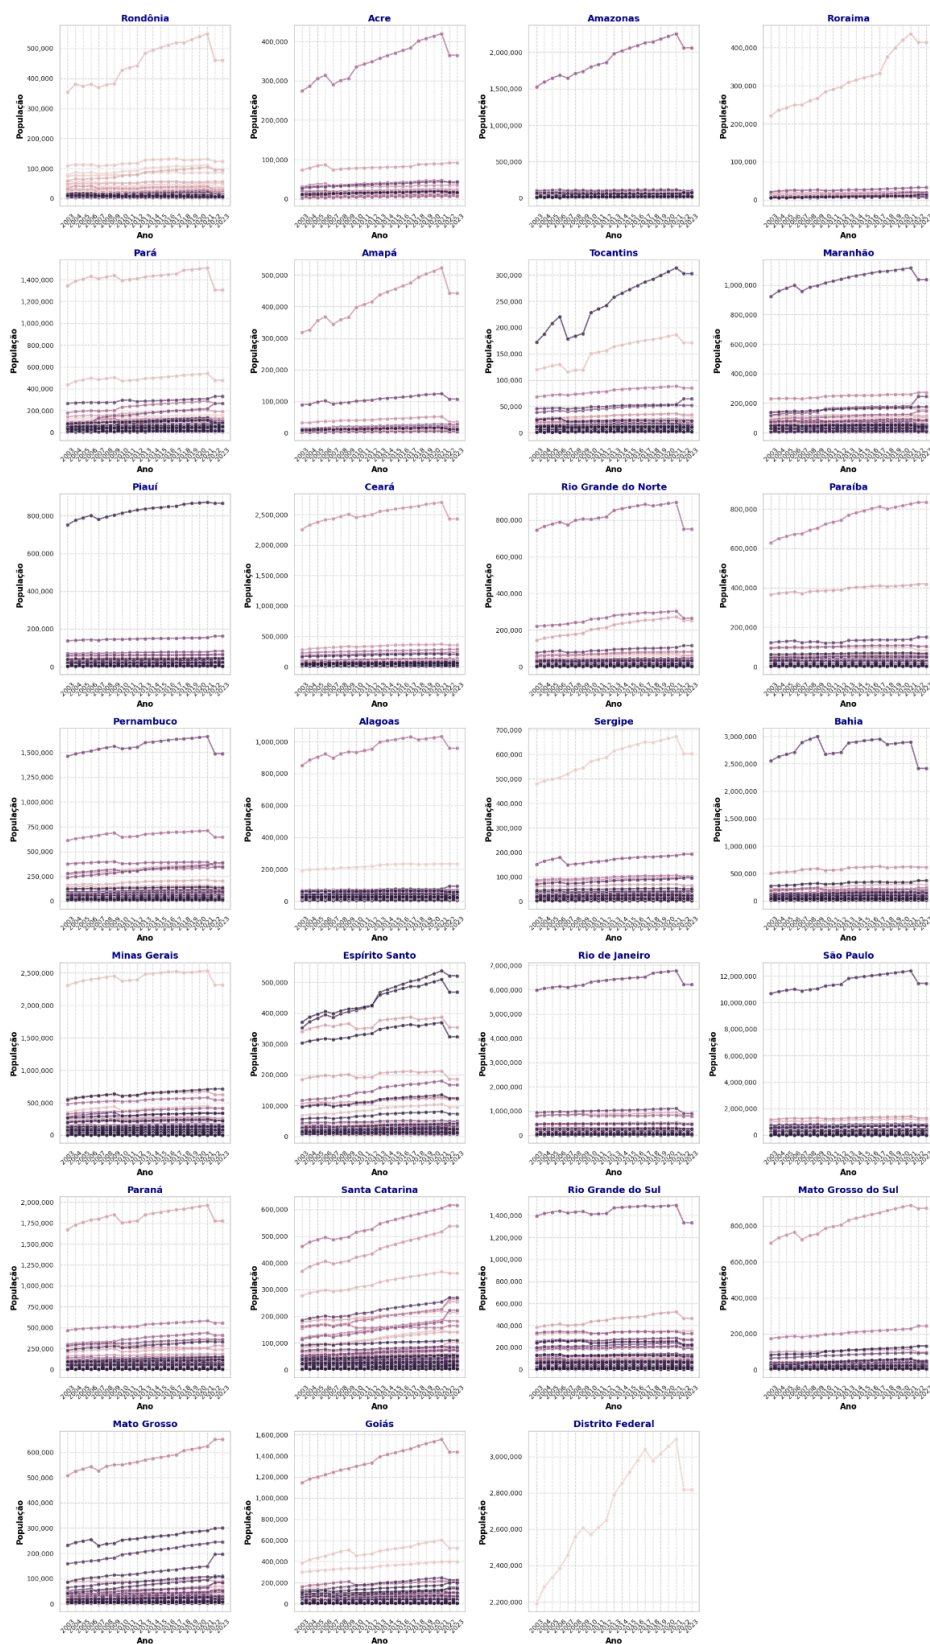


Gráfico 7. Séries temporais de populações municipais por unidades da federação do Brasil. Elaboração: o autor. Fonte: IBGE, 2023.

A análise exploratória dos dados populacionais dos municípios brasileiros em geral (Figura 7) revela padrões significativos de variação demográfica ao longo das últimas duas décadas. Observa-se que a mediana populacional dos municípios manteve-se relativamente estável entre 2003 (10.431 habitantes), 2012 (11.040 habitantes) e 2023 (11.068 habitantes), indicando que, para a maioria dos municípios, o crescimento populacional foi modesto. No entanto, a ampla variação nos valores de população e taxas de crescimento sugere disparidades expressivas entre os municípios. A variância populacional aumentou ao longo dos anos, evidenciando um crescimento desigual entre os municípios, com alguns registrando forte expansão populacional, enquanto outros apresentaram estabilidade ou até mesmo redução demográfica.

As taxas proporcionais de variação da população reforçam essa tendência heterogênea. Entre 2003 e 2012, a variação mediana foi de 5,60%, reduzindo-se para 0,84% no período de 2012 a 2023, o que indica um arrefecimento do crescimento demográfico na última década. No entanto, a amplitude das taxas de variação mostra que alguns municípios cresceram até 227% entre 2003 e 2012 e até 167% entre 2012 e 2023, enquanto outros encolheram drasticamente, com quedas de até 58,9% e 46,7%, respectivamente. No período total de 2003 a 2023, a variação populacional mediana foi de 6,38%, com alguns municípios crescendo até 534% e outros reduzindo sua população em até 64,1%. Essa ampla dispersão pode refletir processos complexos de migração, mudanças econômicas e transformações estruturais que impactam diferentemente os municípios, reforçando a necessidade de abordagens mais flexíveis para a classificação municipal.

Estatística Descritiva						
	POP_03	POP_12	POP_23	PROP_VAR_POP_2003_2012	PROP_VAR_POP_2012_2023	PROP_VAR_POP_2003_2023
N	5560	5570	5570	5560	5570	5560
Mediana	10431	11040	11068	0.0560	0.00838	0.0638
Variância	3.66e+10	4.23e+10	4.26e+10	0.0293	0.0181	0.0804
Amplitude	1.07e+7	11375878	11451166	2.85	2.14	5.98
Mínimo	809	807	833	-0.589	-0.467	-0.641
Máximo	1.07e+7	11376685	11451999	2.27	1.67	5.34

Figura 7. Estatística descritiva dos dados populacionais dos municípios brasileiros. Elaboração: o autor. Fonte: IBGE, 2023.

A análise exploratória dos dados populacionais por macrorregião (Figura 8) revela diferenças marcantes nas dinâmicas demográficas das distintas regiões do Brasil. Observou-se que, em termos de mediana populacional, o Nordeste apresentou os municípios com maior população em 2003 (13.319 habitantes), seguido pela região Norte (12.543 habitantes), enquanto o Sul registrou a menor mediana (6.953 habitantes). Ao longo das duas últimas décadas, a população mediana aumentou em todas as regiões, com destaque para o Norte, cuja mediana cresceu cerca de 25,3% entre 2003 e 2023, e o Centro-Oeste, que também apresentou crescimento

expressivo (15,0%). Por outro lado, o Nordeste mostrou um comportamento distinto, com crescimento entre 2003 e 2012 (4,7%), mas uma leve redução entre 2012 e 2023 (-1,0%), sugerindo um possível êxodo ou redistribuição da população na região.

A variância populacional foi maior na região Sudeste, refletindo a presença de municípios com grandes disparidades populacionais, como as metrópoles altamente povoadas e pequenos municípios de baixa densidade. Esse fenômeno é evidente ao observar a amplitude dos valores populacionais, com o Sudeste possuindo o maior intervalo, variando de menos de mil habitantes até mais de 11 milhões em 2023. Em contraste, a região Sul apresentou a menor variância, indicando uma distribuição mais homogênea do tamanho populacional entre seus municípios.

As taxas proporcionais de variação populacional evidenciam padrões regionais distintos. O Norte apresentou a maior variação acumulada entre 2003 e 2023 (18,8%), demonstrando um forte crescimento populacional relativo, impulsionado por processos migratórios e dinâmicas de ocupação territorial. O Centro-Oeste também teve um aumento considerável (12,8%), refletindo a expansão de municípios do agronegócio e do entorno do Distrito Federal. Já o Sul apresentou a menor taxa de crescimento proporcional (2,67%), indicando uma estabilidade demográfica maior. O Nordeste, além de registrar a menor variação proporcional entre 2012 e 2023 (-0,49%), teve a maior amplitude negativa, com municípios que perderam até 64,1% de sua população, evidenciando desafios de fixação populacional em determinadas áreas.

Essas diferenças regionais ressaltam a importância de considerar as especificidades locais ao analisar dinâmicas populacionais. Enquanto algumas regiões experimentam forte crescimento, outras passam por processos de estagnação ou declínio populacional, exigindo abordagens diferenciadas para o planejamento urbano e regional.

Estatística Descritiva							
	Macrorregião	POP_03	POP_12	POP_23	PROP_VAR_POP_2003_2012	PROP_VAR_POP_2012_2023	PROP_VAR_POP_2003_2023
N	Norte	449	450	450	449	450	449
	Nordeste	1792	1794	1794	1792	1794	1792
	Sudeste	1668	1668	1668	1668	1668	1668
	Sul	1188	1191	1191	1188	1191	1188
	Centro-Oeste	463	467	467	463	467	463
Mediana	Norte	12543	15332	15720	0.151	0.0268	0.188
	Nordeste	13319	13947	13802	0.0688	-0.00493	0.0560
	Sudeste	10089	10647	10884	0.0519	0.0148	0.0685
	Sul	6953	7074	7184	0.0153	0.0136	0.0267
	Centro-Oeste	8093	8615	9303	0.0848	0.0428	0.128
Variância	Norte	1.06e+10	1.43e+10	1.60e+10	0.0800	0.0350	0.205
	Nordeste	1.05e+10	1.25e+10	1.16e+10	0.0231	0.0121	0.0492
	Sudeste	9.93e+10	1.13e+11	1.13e+11	0.0197	0.0119	0.0516
	Sul	5.72e+9	6.43e+9	6.79e+9	0.0149	0.0202	0.0693
	Centro-Oeste	1.55e+10	2.19e+10	2.55e+10	0.0548	0.0362	0.174
Amplitude	Norte	1.53e+6	1860789	2062525	2.22	2.11	5.84
	Nordeste	2.56e+6	2709732	2427390	2.85	1.90	4.95
	Sudeste	1.07e+7	11375878	11451166	2.32	1.13	3.17
	Sul	1.67e+6	1775529	1772583	1.24	1.20	2.45
	Centro-Oeste	2.19e+6	2647493	2816457	1.77	1.98	2.95
Mínimo	Norte	992	1049	1164	-0.496	-0.459	-0.493
	Nordeste	1200	1236	1318	-0.589	-0.467	-0.641
	Sudeste	809	807	833	-0.295	-0.319	-0.446
	Sul	1133	1232	1135	-0.432	-0.237	-0.477
	Centro-Oeste	903	1039	924	-0.353	-0.308	-0.337
Máximo	Norte	1.53e+6	1861838	2063689	1.72	1.65	5.34
	Nordeste	2.56e+6	2710968	2428708	2.27	1.43	4.31
	Sudeste	1.07e+7	11376685	11451999	2.03	0.809	2.72
	Sul	1.67e+6	1776761	1773718	0.804	0.964	1.98
	Centro-Oeste	2.19e+6	2648532	2817381	1.42	1.67	2.61

Figura 8. Estatística descritiva dos dados populacionais dos municípios brasileiros por Macrorregião. Elaboração: o autor. Fonte: IBGE, 2023.

A estatística descritiva dos dados populacionais dos municípios brasileiros entre 2003 e 2023 (Apêndices 3 e 4) revelam padrões distintos de crescimento e declínio demográfico em diferentes macrorregiões e unidades da federação. A mediana da população nos estados variou significativamente ao longo do período analisado, refletindo tendências de urbanização, migração e mudanças econômicas. Estados como Pará e Rio de Janeiro apresentam medianas populacionais elevadas ao longo do tempo, enquanto estados como, Tocantins e Piauí, mostram um crescimento mais expressivo em termos proporcionais. A variação proporcional da população também evidencia contrastes regionais, com estados como Acre e Amazonas registrando aumentos significativos, enquanto estados como Rio Grande do Sul e Bahia apresentam taxas de variação menos expressivas ou até mesmo negativas em determinados períodos.

A dispersão da população nos municípios, medida pela variância e amplitude, também demonstra diferenças regionais marcantes. A amplitude, que representa a diferença entre os municípios mais e menos populosos dentro de cada estado, mostra valores expressivos em estados com grandes metrópoles, como São Paulo e Rio de Janeiro, indicando forte concentração populacional em determinadas áreas. Esses padrões estatísticos são fundamentais para compreender as dinâmicas populacionais ao longo do tempo.

No que refere-se aos testes estatísticos de comparação de grupos, o teste de Kruskal-Wallis (Figura 9 e 10) demonstrou que entre para as variáveis de população (Populações absolutas e variações populacionais proporcionais) às macrorregiões e unidades da federação diferem significativamente, o que demonstra a heterogeneidade do território brasileiro nas questões populacionais, mesmo que para algumas macrorregiões essa comparação seja significativa (Figura 11).

Kruskal-Wallis			
	χ^2	gl	p
POP_03	215	4	< .001
POP_12	238	4	< .001
POP_23	201	4	< .001
PROP_VAR_POP_2003_2012	290	4	< .001
PROP_VAR_POP_2012_2023	113	4	< .001
PROP_VAR_POP_2003_2023	156	4	< .001

Figura 9. Teste de Kruskal-Wallis para variáveis de população por Macrorregião. Elaboração: o autor. Fonte: IBGE, 2023.

Kruskal-Wallis			
	χ^2	gl	p
POP_03	1021	26	< .001
POP_12	1053	26	< .001
POP_23	1015	26	< .001
PROP_VAR_POP_2003_2012	630	26	< .001
PROP_VAR_POP_2012_2023	465	26	< .001
PROP_VAR_POP_2003_2023	587	26	< .001

Figura 10. Teste de Kruskal-Wallis para variáveis de população por Unidade da Federação. Elaboração: o autor. Fonte: IBGE, 2023.

Comparações múltiplas - POP_03				Comparações múltiplas - POP_12				Comparações múltiplas - POP_23			
		W	p			W	p			W	p
Norte	Nordeste	1.24	0.906	Norte	Nordeste	-0.914	0.967	Norte	Nordeste	-1.82	0.701
Norte	Sudeste	-2.63	0.338	Norte	Sudeste	-4.546	0.011	Norte	Sudeste	-4.47	0.014
Norte	Sul	-10.47	<.001	Norte	Sul	-12.864	<.001	Norte	Sul	-12.31	<.001
Norte	Centro-oeste	-7.43	<.001	Norte	Centro-oeste	-8.165	<.001	Norte	Centro-oeste	-7.38	<.001
Nordeste	Sudeste	-7.41	<.001	Nordeste	Sudeste	-7.446	<.001	Nordeste	Sudeste	-6.29	<.001
Nordeste	Sul	-19.57	<.001	Nordeste	Sul	-20.501	<.001	Nordeste	Sul	-18.84	<.001
Nordeste	Centro-oeste	-12.09	<.001	Nordeste	Centro-oeste	-11.035	<.001	Nordeste	Centro-oeste	-9.26	<.001
Sudeste	Sul	-11.65	<.001	Sudeste	Sul	-12.750	<.001	Sudeste	Sul	-12.27	<.001
Sudeste	Centro-oeste	-6.47	<.001	Sudeste	Centro-oeste	-5.530	<.001	Sudeste	Centro-oeste	-4.69	0.008
Sul	Centro-oeste	2.19	0.532	Sul	Centro-oeste	3.899	0.046	Sul	Centro-oeste	4.31	0.020

Comparações múltiplas - PROP_VAR_POP_2003_2012				Comparações múltiplas - PROP_VAR_POP_2012_2023				Comparações múltiplas - PROP_VAR_POP_2003_2023			
		W	p			W	p			W	p
Norte	Nordeste	-11.91	<.001	Norte	Nordeste	-6.1782	<.001	Norte	Nordeste	-12.60	<.001
Norte	Sudeste	-13.90	<.001	Norte	Sudeste	-0.6363	0.992	Norte	Sudeste	-10.32	<.001
Norte	Sul	-18.40	<.001	Norte	Sul	-0.0172	1.000	Norte	Sul	-12.98	<.001
Norte	Centro-oeste	-5.25	0.002	Norte	Centro-oeste	4.0735	0.032	Norte	Centro-oeste	-1.71	0.744
Nordeste	Sudeste	-5.65	<.001	Nordeste	Sudeste	11.1882	<.001	Nordeste	Sudeste	3.98	0.039
Nordeste	Sul	-17.16	<.001	Nordeste	Sul	9.3756	<.001	Nordeste	Sul	-5.35	0.001
Nordeste	Centro-oeste	4.44	0.015	Nordeste	Centro-oeste	12.1704	<.001	Nordeste	Centro-oeste	9.67	<.001
Sudeste	Sul	-13.56	<.001	Sudeste	Sul	0.0763	1.000	Sudeste	Sul	-8.69	<.001
Sudeste	Centro-oeste	6.85	<.001	Sudeste	Centro-oeste	6.2945	<.001	Sudeste	Centro-oeste	7.33	<.001
Sul	Centro-oeste	13.24	<.001	Sul	Centro-oeste	5.3536	0.001	Sul	Centro-oeste	11.17	<.001

Figura 11. Teste de comparações múltiplas Dwass-Steel-Critchlow-Fligener para variáveis de população por Macrorregião. Elaboração: o autor.

Através da representação cartográfica (Figura 19), é possível identificar padrões regionais de variação populacional, como o aumento expressivo em certas áreas metropolitanas e o declínio em regiões mais periféricas ou com menor infraestrutura de serviços. Esses dados podem ser utilizados para planejar políticas públicas, direcionando recursos para áreas com maior crescimento e intervenções em locais com queda populacional, buscando melhorar as condições de vida e infraestrutura dos municípios. Além disso, a comparação entre os períodos de 2003-2012 e 2012-2023 oferece *insights* sobre tendências recentes e os impactos de fatores econômicos, sociais e ambientais na dinâmica populacional.

Ao realizar a análise por uma perspectiva geral de municípios, nota-se que a região Norte apresenta a maior quantidade de municípios ganhando e também perdendo população, se comparado com os períodos iniciais, podendo refletir dinâmicas de migração interestaduais. A simbologia padronizada, com a centralização no valor 0, facilita a interpretação das mudanças, destacando áreas com variações positivas e negativas. Municípios com cores mais quentes (valores positivos) indicam crescimento populacional, enquanto as cores mais frias (valores negativos) revelam uma redução em relação ao início do período.

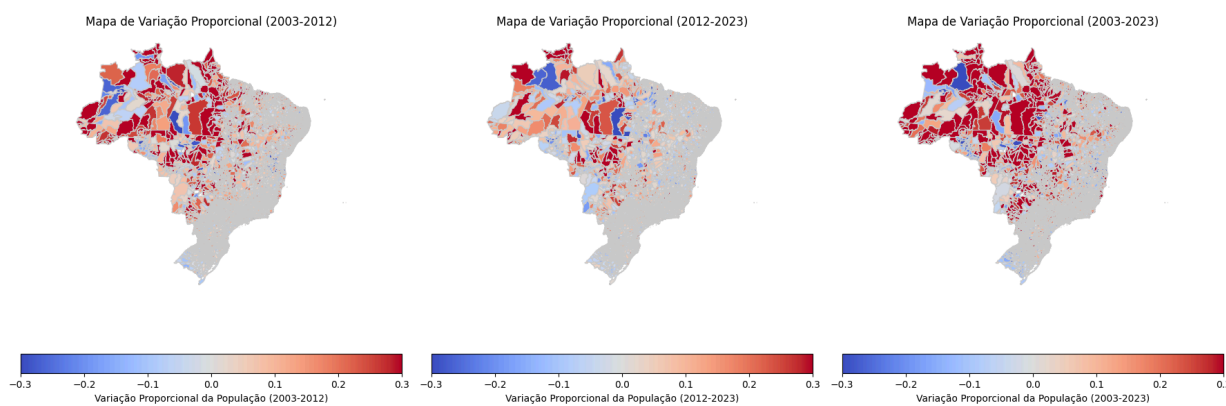


Figura 12. Mapas de variação proporcional de população. Elaboração: o autor. Fonte: IBGE, 2023.

As correlações observadas nos dados demográficos (Gráfico 8) indicam a força e a direção das associações entre diferentes características, como a população de cada ano e as variações populacionais nos intervalos entre 2003-2012, 2012-2023, e o período total de 2003-2023. A correlação de 1 na diagonal reflete a correlação perfeita de cada variável consigo mesma.

Primeiramente, é possível perceber que as variáveis de população total de 2003, 2012 e 2023 apresentam correlações bastante altas entre si. Isso é esperado, já que a população de um ano é fortemente influenciada pela população do ano anterior, embora os valores absolutos possam variar ao longo do tempo. Por exemplo, a correlação entre as populações de 2003 e 2012 é positiva e significativa, indicando uma tendência consistente de crescimento ou diminuição populacional entre esses anos. Similarmente, as correlações entre 2012 e 2023 também apresentam valores fortes, sugerindo continuidade nas tendências de crescimento ou declínio populacional.

Por outro lado, as variáveis relacionadas às variações populacionais (como VAR_POP_2003_2012, VAR_POP_2012_2023, VAR_POP_2003_2023) mostram correlações mais baixas, mas ainda relevantes, com as populações absolutas. Isso sugere que as variações demográficas não estão completamente determinadas pela população total de cada ano, mas sim por mudanças mais complexas, como mortalidade, fecundidade e migração. O mesmo padrão se aplica às variáveis de proporção de variação (PROP_VAR_POP_2003_2012, PROP_VAR_POP_2012_2023, PROP_VAR_POP_2003_2023), que refletem a intensidade das mudanças em termos percentuais e podem indicar mais claramente os impactos de mudanças socioeconômicas ou políticas.

Essas correlações fornecem uma introdução para entender as dinâmicas demográficas nos municípios e, ao mesmo tempo, indicam onde fatores externos, como a migração ou mudanças

econômicas, podem ter desempenhado um papel significativo na evolução da população ao longo do tempo. A interpretação dessas relações é crucial para compreender como a estrutura populacional se ajusta ao longo das décadas.




Gráfico 8. Matriz de correlação entre variáveis da dimensão demográfica. Elaboração: o autor. Fonte: IBGE, 2023.

A compreensão das dinâmicas demográficas municipais, por sua vez, não se dá de forma isolada: ela está intrinsecamente ligada ao modo como os territórios são ocupados, utilizados e transformados ao longo do tempo. A forma como a população se distribui, cresce ou se desloca reflete e, ao mesmo tempo, condiciona os processos de uso da terra, revelando um ciclo contínuo de retroalimentação entre sociedade e espaço. Municípios com expansão urbana acelerada, por exemplo, tendem a apresentar pressões distintas sobre os recursos naturais e sobre a estrutura fundiária em comparação àqueles com padrões estáveis ou em retração populacional. Assim, ao integrar os dados territoriais e demográficos, abre-se o caminho para uma análise mais ampla e articulada com os padrões de uso e cobertura da terra, tema que será desenvolvido na próxima seção.

2.4. Uso e cobertura da terra nos municípios: dinâmicas e padrões espaciais

O uso e cobertura da terra nos municípios brasileiros refletem uma série de dinâmicas territoriais, econômicas e sociais que variam de acordo com características locais, como o tipo de atividade predominante, o nível de urbanização e as políticas públicas adotadas. Este tema é crucial para entender as transformações no espaço municipal ao longo do tempo, especialmente quando observamos a interação entre os diferentes tipos de uso da terra, como áreas urbanas, rurais, florestais e agrícolas. As dinâmicas de uso da terra podem ser analisadas em função de transformações em áreas urbanizadas, expansão agrícola, desmatamento, recuperação de áreas de vegetação nativa, entre outros aspectos.

A partir de dados estatísticos do MapBiomas, foi possível analisar essas dinâmicas de forma detalhada, observando a distribuição e as mudanças no uso e cobertura da terra de 2003 a 2023. A expansão das áreas urbanas e agrícolas, por exemplo, têm avançado de maneira desigual, com padrões distintos entre as regiões Norte, Nordeste, Sul e Sudeste. Além disso, as dinâmicas de uso da terra estão intimamente relacionadas a fatores demográficos, econômicos, ambientais e políticos com o crescimento urbano associando-se a pressões sobre áreas rurais e florestais, ao passo que o agronegócio continua a expandir-se nas regiões Centro-Oeste e Norte, impactando significativamente a vegetação nativa.

Para retratar essas dinâmicas sobre a dimensão relacionada às classes de cobertura da terra, elaborou-se os gráficos das séries temporais relacionadas às classes de áreas florestais (Gráficos 9 e 10) e áreas não-vegetada (Gráficos 11 e 12). Após isso, verifica-se a comparação entre regiões através dos testes estatísticos.

A região Norte se destaca com as maiores proporções de cobertura florestal, mantendo valores elevados ao longo do tempo. No entanto, alguns municípios apresentam tendência de redução, visualmente representados por ranhuras verdes na área amarela e/ou ranhuras amarelas na área alaranjada. Além disso, a região Norte exibe uma menor concentração de municípios com baixa cobertura florestal (<30%). As Regiões Nordeste, Sudeste e Sul possuem uma dinâmica mais heterogênea, representado pela densidade distribuída de municípios entre as faixas de proporção. Alguns municípios apresentam elevada cobertura (>75%), enquanto outros registram valores mais baixos (<50%). Algumas macrorregiões apresentaram tendência de redução da cobertura florestal em determinados municípios, especialmente no Centro-Oeste e Norte, indicando possíveis processos de desmatamento e expansão agrícola. Na Região Sul e Sudeste, há

municípios que mantêm valores estáveis ou até apresentam crescimento da cobertura florestal, possivelmente associado a iniciativas de reflorestamento ou regeneração de áreas nativas.

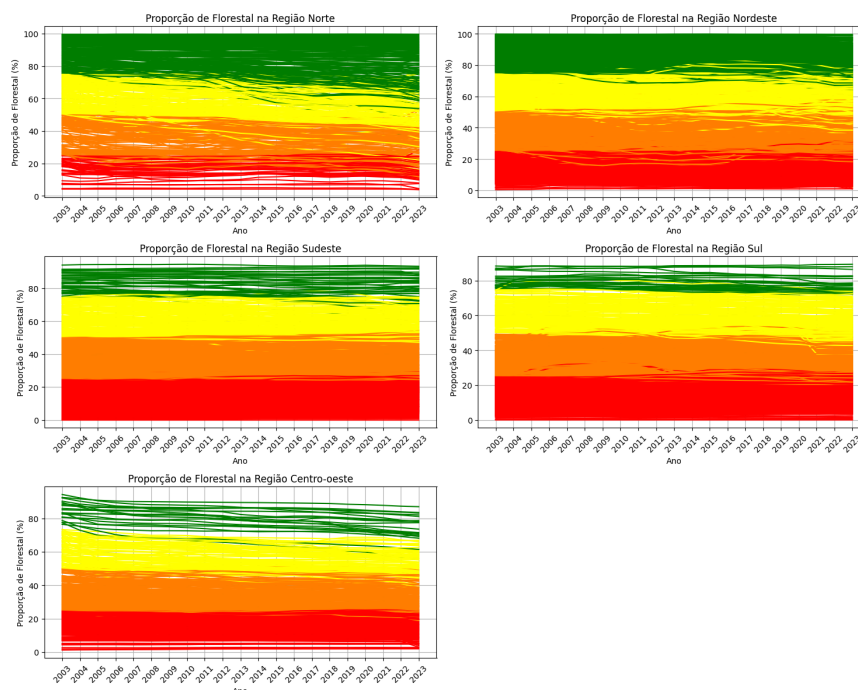


Gráfico 9. Séries temporais cobertura florestal percentual municipais por macrorregião do Brasil. Elaboração: o autor.

Fonte: MAPBIOMAS, 2023.

Considerando uma análise por estados Acre, Amazonas, Amapá, Pará, Rondônia, Roraima, Piauí e Ceará possuem os maiores valores de cobertura florestal, frequentemente superiores a 90%. Tocantins e Mato Grosso possuem municípios com alta cobertura, mas exibem variações ao longo do tempo, sugerindo perdas em algumas áreas. Os estados de Alagoas, Espírito Santo, Mato Grosso do Sul e Sergipe possuem as proporções mais baixas de cobertura florestal no período analisado, e suas tendências demonstram-se instáveis.

Estados amazônicos, como Amazonas, Amapá e Acre, mantêm alta cobertura florestal, mas há indícios de variações em alguns municípios, possivelmente refletindo impactos do desmatamento e da expansão agropecuária. No Mato Grosso, Maranhão e Tocantins, observa-se uma tendência de redução florestal em determinados municípios, alinhada com as fronteiras de expansão agrícola. Algumas UFs apresentam aumento na cobertura florestal em determinados municípios, o que pode estar relacionado a processos de restauração ecológica ou regeneração natural.

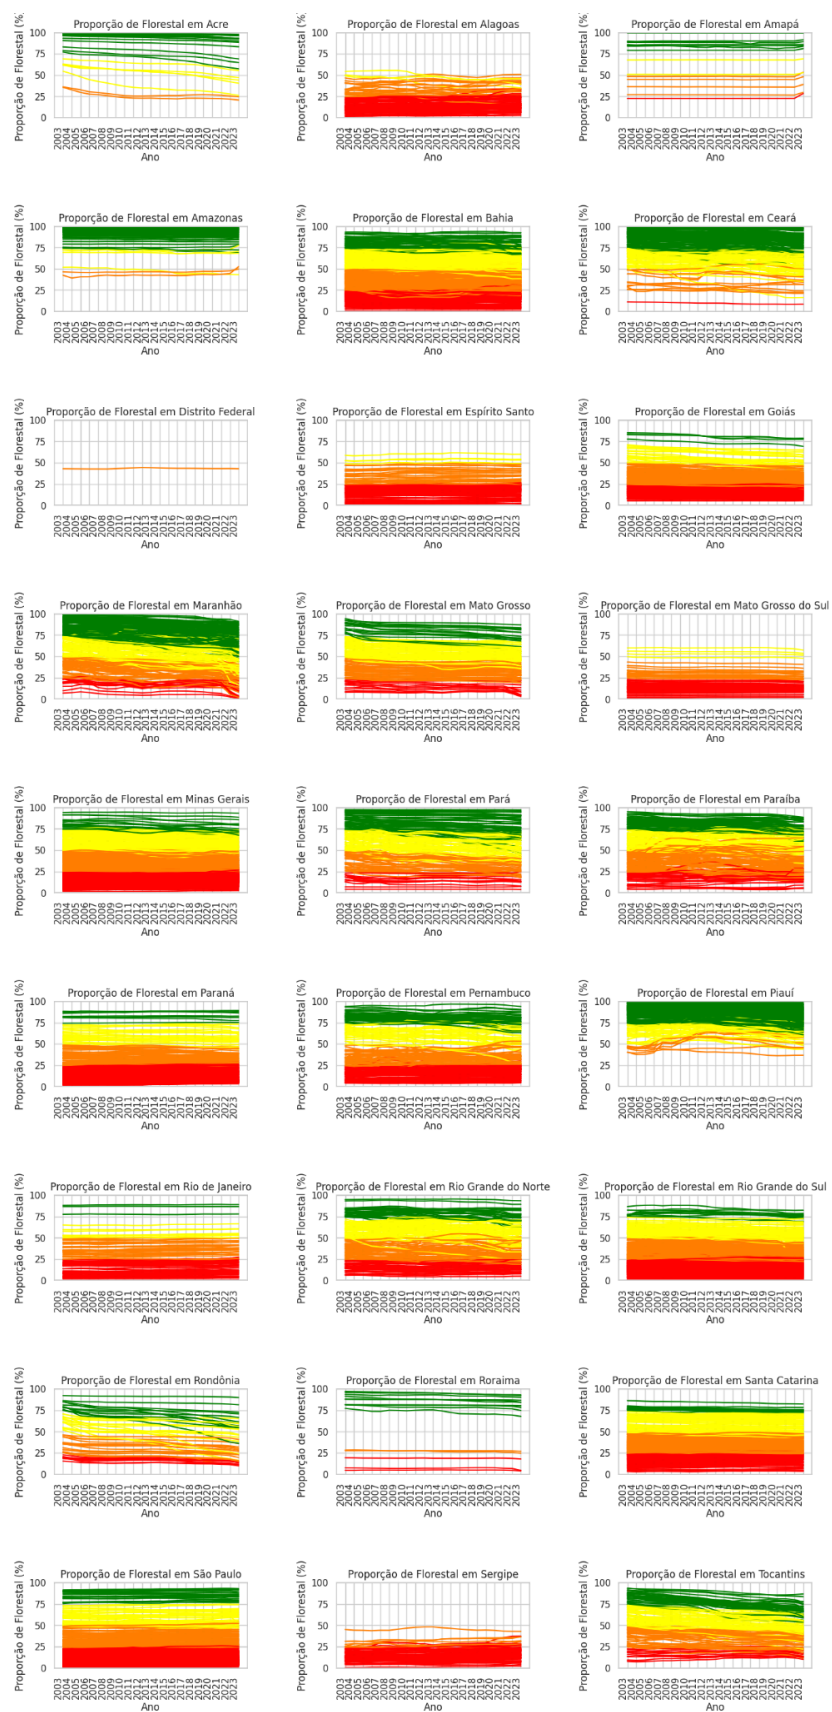


Gráfico 10. Séries temporais cobertura florestal percentual municipais por unidade da federação do Brasil.

Elaboração: o autor. Fonte: MAPBIOMAS, 2023.

De um modo panorâmico, as cinco regiões do Brasil apresentam tendências de crescimento da classe de cobertura de área não vegetada, com destaque para o Centro-oeste possuindo curvas mais acentuadas. Enquanto na região norte os valores para cobertura florestal mostraram-se elevados (>80%), para o aspecto de área não-vegetada os valores são os mais baixos entre as cinco regiões, com tendência de crescimento lento para o período de 2003 a 2012.




Gráfico 11. Séries temporais de cobertura de área não vegetada percentual municipais por macrorregião do Brasil.

Elaboração: o autor. Fonte: MapBiomass, 2023.

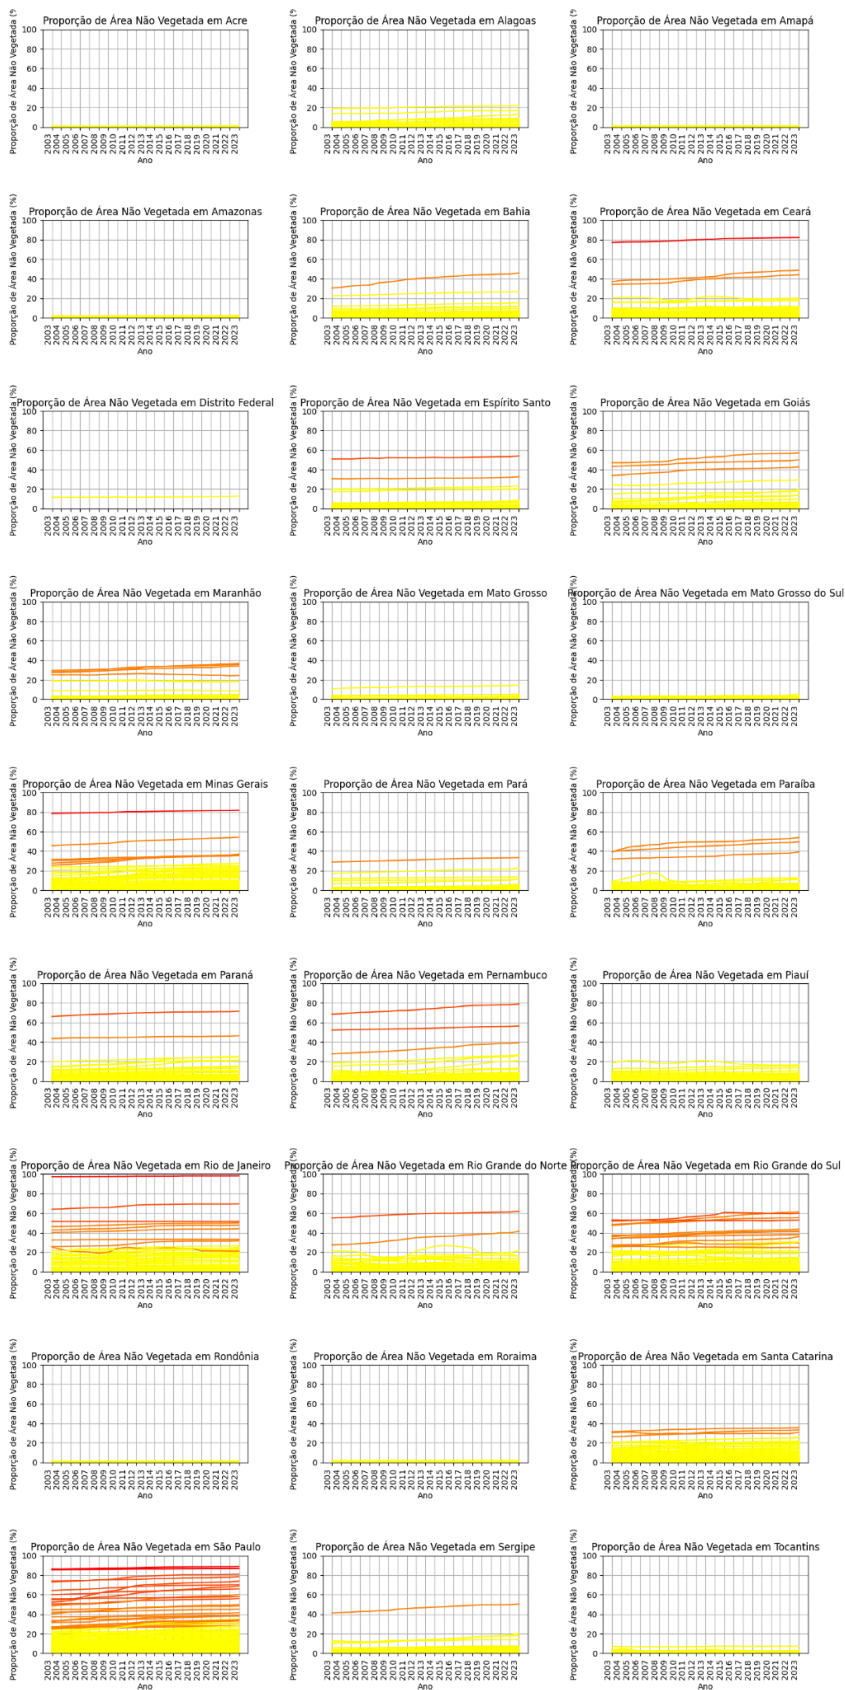


Gráfico 12. Séries temporais de cobertura de área não vegetada percentual municipais por unidades da federação do Brasil. Elaboração: o autor. Fonte: MAPBIOMAS, 2023.

As variações observadas na cobertura florestal e nas áreas não vegetadas apresentam uma grande heterogeneidade, tanto dentro das macrorregiões quanto entre os estados. A Região Norte ainda concentra a maior parte das florestas brasileiras, mas há sinais de perda em alguns municípios, especialmente nas bordas da Amazônia.

Essas mudanças refletem um complexo conjunto de processos ambientais e socioeconômicos, como o desmatamento, a recuperação de áreas nativas e as dinâmicas territoriais específicas de cada estado e região, intrinsecamente conectadas ao modo de produção global e a condução de políticas protecionistas – ou não – dos países e suas estratégias de desenvolvimento (Sauer, 2024).

O Gráfico 13, ilustra a evolução das correlações anuais entre diferentes classes de cobertura do solo no Brasil, entre 2003 e 2023. Essas correlações incluem variáveis relacionadas à cobertura de solo por florestas, formações naturais não florestais, agropecuária, áreas não vegetadas e ambientes aquáticos. A Cobertura Florestal refere-se a áreas cobertas por vegetação natural, como árvores, arbustos e plantas lenhosas, com densidade variável, abrangendo desde florestas primárias e secundárias até zonas de regeneração natural e áreas com vegetação esparsa. Já a classe Agropecuária engloba tanto o uso do solo para o cultivo agrícola, incluindo culturas temporárias (como grãos e hortaliças) e permanentes (como café e cana-de-açúcar), quanto para a criação de animais (pecuária) ou sistemas integrados de agricultura e pecuária. Essas duas classes estão frequentemente em conflito, com a expansão da agricultura e pecuária pressionando as áreas de cobertura florestal, o que leva ao desmatamento em várias regiões (MAPBIOMAS, 2021).

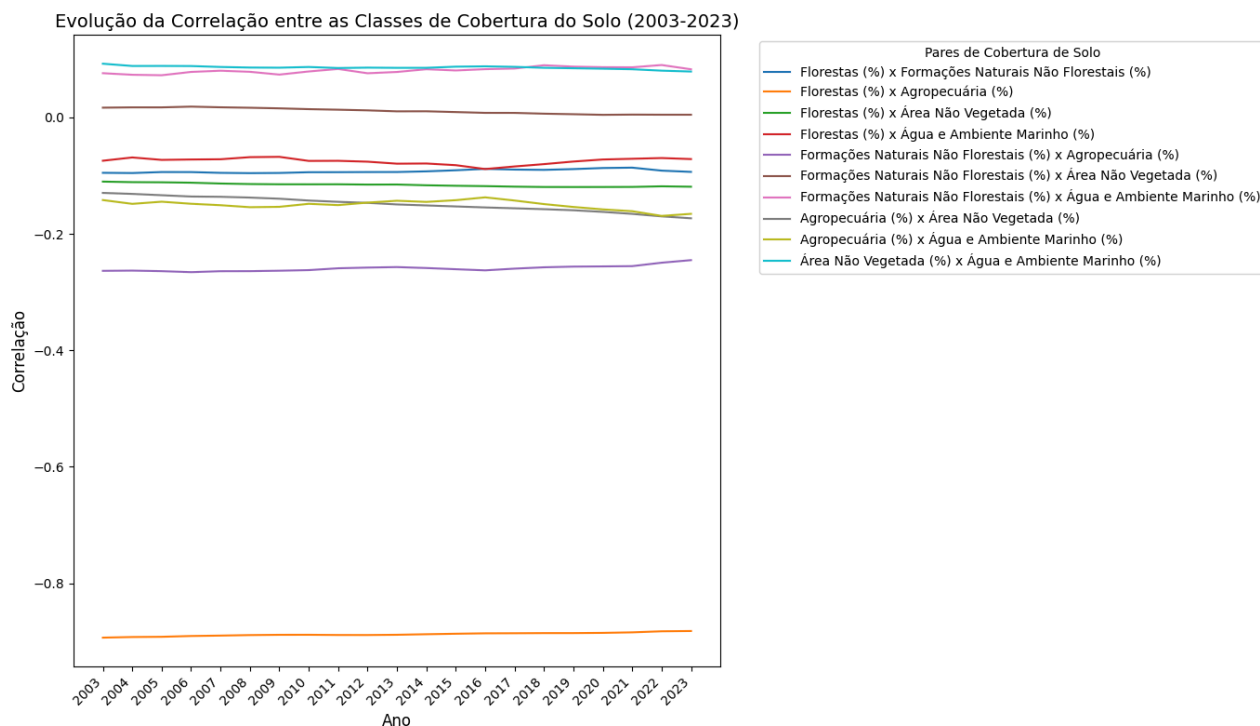


Gráfico 13. Séries temporais de pares de cobertura das terras municipais Brasil. Elaboração: o autor. Fonte: MapBiomias, 2023.

Separado pelas macrorregiões e unidades da federação (Gráficos 14 e 15), a correlação entre as diferentes classes de uso e cobertura das terras, apresentou-se com uma dinâmica semelhante para os cinco grupos, porém com intensidade diferente, observada pela escala do eixo y. Ao incorporar o aspecto das macrorregiões e das unidades da federação na análise das correlações entre as classes de cobertura do solo, observou-se uma diferenciação significativa nos padrões e intensidades dessas correlações.

Enquanto a análise geral do Brasil revelou uma visão ampla e simplificada das dinâmicas entre as classes de uso da terra, a segmentação por macrorregiões e unidades da federação permite identificar variações regionais mais sutis. Por exemplo, nas regiões Norte e Centro-Oeste, a correlação entre cobertura florestal e agropecuária mostra-se mais forte influenciada pelo avanço da fronteira agrícola em áreas de vegetação nativa rasteira, enquanto em estados Sudeste, o comportamento dessas correlações pode refletir um equilíbrio mais estável entre as classes ou até mesmo uma pressão diferenciada sobre as áreas florestais e área não-vegetadas (majoritariamente representada por estruturas urbanas). A incorporação das macrorregiões e das unidades da federação no detalhamento da análise também permitiu captar dinâmicas locais que seriam diluídas em uma abordagem nacional agregada. Determinadas correlações que se mostram fracas ou inexistentes no cenário geral ganham destaque quando observadas em recortes territoriais específicos, revelando padrões regionais de uso da terra mais complexos.




Gráfico 14. Séries temporais de pares de cobertura das terras municipais por macrorregiões do Brasil. Elaboração: o autor. Fonte: MAPBIOMAS, 2023.

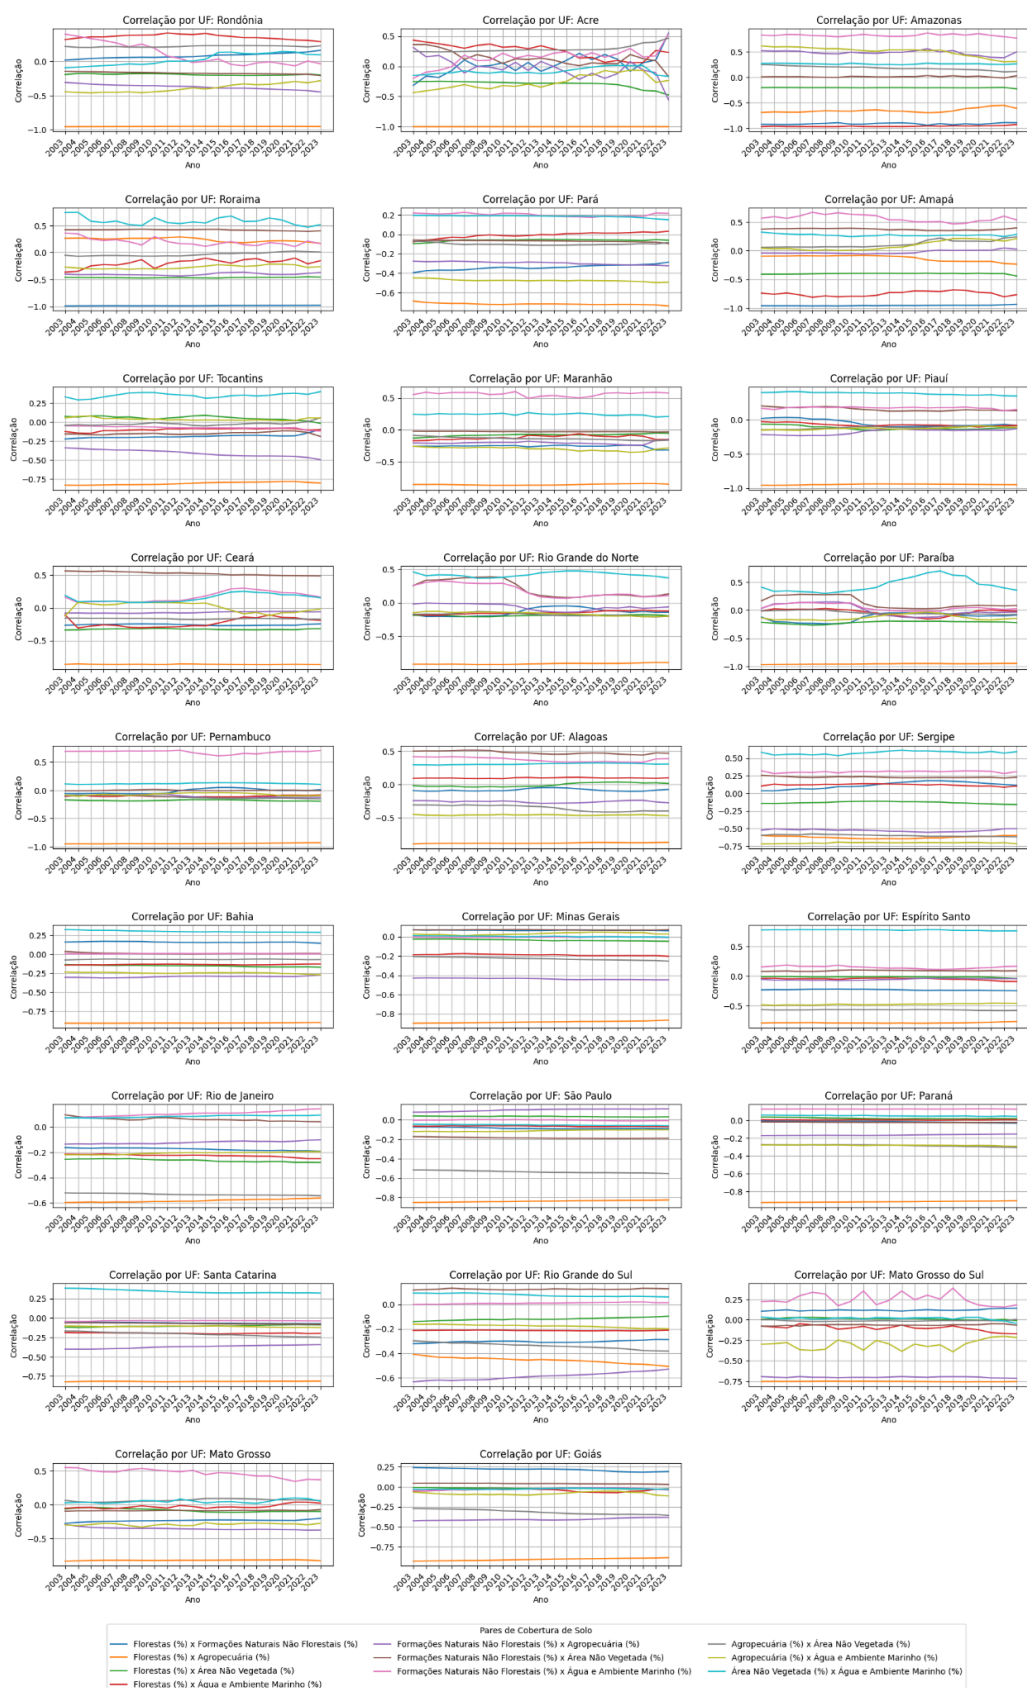


Gráfico 15. Séries temporais de pares de cobertura das terras municipais por Unidades da Federação do Brasil.

Elaboração: o autor. Fonte: MAPBIOMAS, 2023.

A diferenciação observada nas correlações entre classes de cobertura do solo quando analisadas por macrorregiões e unidades da federação reforçou a importância de se considerar as especificidades territoriais nas análises ambientais e espaciais. Essa heterogeneidade regional evidencia que as dinâmicas de uso e ocupação da terra não seguem um padrão único em todo o país, mas variam conforme contextos socioeconômicos, históricos e ambientais. Tais diferenças apontam para os limites das análises nacionais agregadas e indicam a necessidade de abordagens mais granulares e sensíveis às particularidades locais. Nesse sentido, os resultados obtidos sustentam a discussão sobre a adequação das estratificações territoriais atualmente utilizadas no Brasil, introduzindo a próxima seção, que trata das limitações desses modelos tradicionais e da urgência por novas metodologias classificatórias que consigam refletir com mais precisão a complexidade dos territórios municipais.

2.5. Estratificações existentes e a necessidade de novas abordagens

A análise territorial dos municípios brasileiros frequentemente se apoia em diferentes estratificações que buscam classificar as áreas de acordo com suas características socioeconômicas, demográficas e ambientais (Bremaeker, 1996; Magalhães, 2008; Sposito, 2024; IBGE, 2025). Essas estratificações têm sido fundamentais para a formulação de políticas públicas e para a compreensão das disparidades entre as diversas regiões do país. No entanto, as abordagens tradicionais de estratificação, muitas vezes baseadas em critérios como extensão territorial, população ou uso da terra, podem não ser suficientes para captar toda a complexidade das dinâmicas municipais. Isso se deve, em parte, às mudanças rápidas e intensas nas características territoriais, que exigem uma abordagem mais dinâmica e integrada, como demonstrado nos capítulos anteriores. A crescente heterogeneidade entre os municípios, impulsionada pela urbanização, pela industrialização e por transformações no uso da terra, demanda uma revisão desses modelos tradicionais de classificação, além da implementação de novas abordagens analíticas (IBGE, 2023b).

A utilização da lógica *fuzzy* (Zadeh, 1988), surge como uma abordagem metodológica possível para lidar com as ambiguidades e sobreposições existentes entre as diferentes categorizações populacionais dos municípios. Em vez de estabelecer limites rígidos e fixos, como ocorre nas classificações tradicionais, a lógica fuzzy permite atribuir graus de pertinência a cada município dentro de múltiplas categorias. Dessa forma, um município com 98 mil habitantes, por exemplo, pertenceria com graus de pertinência diferenciados, tanto à classe de "municípios pequenos" quanto à de "municípios médios", até mesmo a de grandes segundo a classificação do

MUNIC, evitando distorções abruptas na análise. Essa abordagem possibilita uma transição mais gradual entre as faixas populacionais, reduzindo os problemas metodológicos decorrentes de discrepâncias entre diferentes classificações e promovendo uma visão mais realista das dinâmicas populacionais. Além disso, a lógica fuzzy facilita a integração de múltiplos critérios populacionais, permitindo uma categorização mais flexível e adaptativa aos diferentes contextos municipais. Essa abordagem seria particularmente útil para identificar gradientes territoriais dentro de estados ou mesmo entre estados vizinhos que compartilham dinâmicas semelhantes.

A incorporação de técnicas estatísticas aliadas às de inteligência artificial e aprendizado de máquina pode permitir uma análise mais precisa e flexível, que leve em conta um maior número de variáveis simultaneamente, permitindo uma segmentação mais refinada e condizente com as realidades territoriais contemporâneas. Essas novas abordagens podem também ajudar a identificar padrões regionais e locais que os modelos tradicionais não conseguem capturar, como dinâmicas emergentes de uso da terra, desmatamento, urbanização descontrolada e alterações climáticas. Assim, é essencial que as estratégias de estratificação sejam constantemente revisadas e atualizadas.

2.6 Resultados do capítulo

Por um lado, a Constituição de 1988 estabeleceu um modelo federativo altamente descentralizado, conferindo significativa autonomia aos municípios em termos de arrecadação e execução de políticas. Essa autonomia permite que os governos locais estabeleçam suas próprias prioridades e se adaptem às necessidades específicas de suas populações. Por outro lado, essa mesma autonomia, combinada à desigualdade territorial histórica — especialmente na região Nordeste — expõe a fragilidade de mecanismos de cooperação horizontal. Isso reforça a necessidade de articulações regionais para o enfrentamento de problemas complexos (Monteiro, Anazawa e Oliveira, 2020), e levanta questões sobre a capacidade dos municípios em garantir padrões mínimos de serviços públicos e reduzir desigualdades entre jurisdições (CNM, 2024).

Nesse contexto, a União desempenha um papel crucial por meio da regulação e da redistribuição de recursos. A legislação federal estabelece regras para a arrecadação tributária e vincula parte das receitas municipais a gastos em áreas prioritárias como saúde e educação (Arretche, 2002).

No que se refere às emancipações, o período analisado (2003–2023) apresentou estabilidade. As últimas emancipações ocorreram em 2012, elevando o número total de municípios de 5560 (em 2003) para 5570 (em 2023). Ao analisar essa distribuição por

macrorregião e Unidade da Federação, observa-se disparidade: a macrorregião Nordeste concentra o maior número de municípios (1794), seguida do Sudeste (1668), Sul (1191), Centro-Oeste (467) e Norte (450). Entre os estados, Minas Gerais lidera com 853 municípios, seguido por São Paulo (645) e Rio Grande do Sul (497). Na outra extremidade, destacaram-se os estados da região Norte com menor número de municípios: Roraima (15), Amapá (16), Acre (22), Rondônia (52) e Amazonas (62). Esses padrões refletem heranças históricas e distintos processos de formação territorial.

Quanto à dimensão territorial, há uma lacuna de estudos que consideram a extensão municipal e suas variações em análises socioambientais. A área dos municípios manteve-se praticamente constante entre 2003 e 2023, com exceção de pequenos ajustes promovidos por normativas estaduais. A análise comparativa revela heterogeneidade entre macrorregiões e unidades federativas, considerando a área absoluta em km² nos anos de 2003, 2012 e 2023.

Em relação à variação proporcional da extensão territorial, identificou-se significância estatística apenas entre as regiões Norte e Sul no período de 2003 a 2012. Esse achado exige investigação mais aprofundada. Destacou-se os municípios situados ao longo da fronteira terrestre das regiões Norte e Centro-Oeste: alguns registraram acréscimos de até 2,5 vezes sua área original, enquanto outros perderam quase metade de seu território. Essas mudanças reforçaram a necessidade de estudos específicos, considerando que esses municípios desempenham funções estratégicas e estão sujeitos a legislações diferenciadas (BRASIL, 1979; IBGE, 2022g).

Na dimensão populacional, diversas classificações baseiam-se no número absoluto de habitantes. Exemplos como a pesquisa MUNIC e o Plano Nacional de Habitação (PlanHab) utilizam essa métrica, mas frequentemente não justificam os critérios de categorização. Essa indefinição pode comprometer a comparabilidade entre municípios e regiões.

As séries temporais de população absoluta mostram que, de modo geral, as capitais se distanciam dos demais municípios em tamanho populacional. Esse padrão se reflete nas regiões metropolitanas, marcadas por adensamentos, contrastando com áreas de baixa densidade populacional, inclusive dentro do mesmo estado. Espírito Santo, Santa Catarina e Mato Grosso apresentam distribuições mais homogêneas. Como destaca Santos (2005), “dispersão e concentração dão-se, uma vez mais, de modo dialético, de modo complementar e contraditório.” Assim, encontrando ressonância direta nos processos contemporâneos de urbanização.

De um lado, observou-se a concentração intensa de fluxos econômicos, tecnológicos e de decisões políticas nos grandes centros urbanos, que funcionam como polos de comando e

controle, acumulando infraestrutura, capital humano qualificado e redes globais. De outro, há um processo simultâneo de dispersão territorial de atividades produtivas, serviços e populações, sobretudo em função da elevação dos custos nos centros e da ampliação das conectividades territoriais. Essa dinâmica impacta diretamente as cidades pequenas e médias, que passam a absorver funções intermediárias, como sedes administrativas, logísticas ou residenciais, ao mesmo tempo em que mantêm vínculos de dependência com os grandes centros.

Nesse contexto, torna-se pertinente mobilizar os conceitos de espaços de luz e espaços escuros, também formulados por Milton Santos. Os espaços de luz são aqueles plenamente integrados aos circuitos técnicos, informacionais e financeiros do mundo globalizado; são territórios visíveis, conectados, valorizados e dotados de infraestrutura moderna. Em contrapartida, os espaços escuros são aqueles que permanecem à margem dos fluxos principais, com baixa densidade técnica e informacional, pouca visibilidade institucional e limitado acesso a bens e serviços. Essa distinção não é geograficamente rígida, podendo coexistir dentro de um mesmo município, e expressa justamente o caráter contraditório e seletivo da urbanização brasileira.

Assim, a urbanização nacional é marcada por essa dialética: enquanto as metrópoles concentram poder, recursos e tornam-se espaços de luz, as cidades menores e áreas periféricas frequentemente configuram-se como espaços escuros, refletindo e reforçando desigualdades históricas, representadas na pesquisa através de medidas de variabilidade.

Assim, as taxas proporcionais de variação populacional reforçam essa heterogeneidade. Entre 2003 e 2012, a variação mediana foi de 5,60%, reduzindo-se para 0,84% entre 2012 e 2023 — indicando um arrefecimento do crescimento demográfico. A distribuição regional dessas variações revela padrões distintos: no estado de São Paulo, observa-se a maior variação, refletindo a desigualdade distributiva da população. A heterogeneidade é marcante tanto nas variáveis absolutas quanto nas proporcionais, com exceções nas regiões Norte e Centro-Oeste, que apresentaram variações populacionais significativas entre 2003 e 2023. A elaboração de mapas auxilia na visualização dessas dinâmicas, evidenciando, por exemplo, os expressivos crescimentos nas regiões Norte e Centro-Oeste.

No que se refere ao uso e cobertura da terra, os dados evidenciam a complexidade dos processos territoriais que caracterizam os municípios brasileiros. A partir da análise de gráficos de coordenadas paralelas, organizados por macrorregiões e unidades da federação, observa-se que muitos municípios da região Norte, especialmente no Amazonas e no Acre, apresentam predominância de formações florestais. Essa característica pode refletir a inserção desses

territórios na Amazônia Legal e políticas específicas de preservação ambiental, como o Código Florestal.

Entretanto, a conservação não é uniforme: o avanço de atividades como agronegócio, mineração e infraestrutura tem provocado transformações significativas, muitas vezes diluídas nas estatísticas agregadas, mas com impactos diretos sobre comunidades locais (Becker, 1996).

Em contraste, a região Centro-Oeste apresenta menor proporção de cobertura vegetal nativa, especialmente em Mato Grosso do Sul e Goiás, onde predomina a agropecuária em larga escala. No Nordeste, Alagoas e Sergipe registram os menores índices de cobertura florestal entre as unidades da federação, reflexo de um processo histórico de ocupação intensiva do solo. Já no Sudeste, destaca-se o elevado grau de urbanização, com municípios cuja área urbana abrange quase a totalidade do território municipal — reflexo do papel histórico da região como centro político, econômico e logístico do país.

As correlações entre as principais classes de uso da terra reforçaram essas distinções regionais. A relação entre áreas florestais e agropecuárias revela correlação negativa significativa em escala nacional (superior a -0,8 entre 2003 e 2023), indicando um processo de substituição de vegetação nativa florestal pela agropecuária em todo o País. Essa tendência é ainda mais acentuada nas regiões Norte e Sul. Já no Nordeste, Sudeste e Centro-Oeste, nota-se uma diminuição dessa correlação, possivelmente indicando estabilização do uso agropecuário em determinadas áreas, ou pela classificação do MapBiomias considerar a fitofisionomia do cerrado dentro da classe de vegetação natural não-florestal.

Observa-se também uma forte correlação entre áreas florestais e áreas de água em algumas unidades da federação, como o Amapá e o Amazonas, o que pode refletir padrões específicos de ocupação próximos a corpos hídricos. Isso exige investigações mais detalhadas, sobretudo onde a expansão urbana e agrícola pressiona ecossistemas aquáticos e zonas úmidas.

Essa diferenciação territorial está diretamente relacionada às dinâmicas demográficas e econômicas previamente discutidas. Ela reflete um processo histórico de ocupação do território que privilegia o litoral e as zonas mais integradas ao mercado nacional e internacional — resultado de uma *mundialização perversa*. A leitura integrada dos resultados permite avançar na compreensão das relações entre forma e conteúdo territorial. A forma, representada pelas divisões político-administrativas dos municípios, impõe limites e possibilidades de ação. Já o conteúdo — as práticas sociais, os fluxos econômicos e os usos concretos do espaço — confere dinamismo ao território e evidencia os conflitos e desigualdades socioambientais nele presentes.

3 APLICAÇÃO DE TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA ANÁLISE MUNICIPAL

3.1. A evolução do uso de técnicas computacionais na geografia e nas ciências ambientais

O uso de técnicas computacionais têm transformado significativamente as ciências ambientais, permitindo análises mais robustas e detalhadas da dinâmica espacial e ambiental (Wang *et al.*, 2022). Inicialmente, os estudos espaciais eram fortemente baseados em métodos cartográficos tradicionais e estatísticas descritivas, mas a introdução de Sistemas de Informação Geográfica (SIG) e sensoriamento remoto revolucionou a forma como os pesquisadores coletam, analisam e interpretam dados territoriais (Ferreira, 2025). Nos últimos anos, o avanço da computação em nuvem, do processamento paralelo e da inteligência artificial tem ampliado as possibilidades de modelagem espacial e previsão de padrões ambientais e socioeconômicos. Apesar dessas técnicas conterem a informação sobre a cobertura das terras – baseado no sensor e na reflectância do *pixel* –, o espaço tem por essência a característica social, carregando em cada unidade de medida, informações herdadas de sociedades pretéritas (Santos, 1997), assim, as mudanças e/ou dinâmicas espaciais ocorrem em causa-efeito da sociedade que se conecta com aquela localidade ou região. Para Wang *et al.* (2022), devemos “socializar o *pixel*”, integrando as informações de cobertura provenientes de satélites e drones com informações de natureza socioambientais, buscando a contemplação de uma totalidade mais abrangente. Técnicas como análise multivariada, redes neurais e *deep learning* estão sendo cada vez mais utilizadas para a detecção de mudanças no uso da terra, previsão de impactos ambientais e estudos de urbanização. Essa evolução tecnológica permite integrar grandes volumes de dados de diferentes fontes, aprimorando a capacidade de análise e tomada de decisão em estudos territoriais.

O Aprendizado de Máquina (AM) aplicado na análise espacial, proporciona novas formas de explorar e compreender as dinâmicas municipais. Modelos supervisionados e não supervisionados podem ser usados para classificar municípios com base em padrões de uso do solo, características socioeconômicas e variações ambientais (Aguar; Baptista, 2023; Favero *et al.*, 2024). Técnicas como agrupamento (*Clustering*) ajudam a identificar padrões espaciais semelhantes entre diferentes municípios, enquanto algoritmos de regressão podem prever tendências futuras relacionadas à expansão urbana, mudanças ambientais ou transformações

demográficas. A combinação de aprendizado de máquina com bases geoespaciais permite uma análise mais detalhada e precisa das interações entre variáveis territoriais, superando limitações dos métodos estatísticos tradicionais (Vilar *et al.*, 2016). Além disso, a aplicação de aprendizado de máquina em séries temporais possibilita o monitoramento contínuo da evolução dos municípios, fornecendo *insights* importantes para planejamento urbano e gestão ambiental.

Assim, a inteligência artificial tem se mostrado uma ferramenta poderosa para a análise integrada de variáveis territoriais, demográficas e ambientais, especialmente no contexto de *Land Use and Land Cover* (LULC) (Wang *et al.*, 2022; Silva *et al.*, 2024). Técnicas de aprendizado supervisionado, como Árvores de decisão (*Decision Trees*), Floresta aleatória (*Random Forest*), Máquina de vetor de suporte (SVM) e *Gradient boosting*, são amplamente empregadas para identificar padrões de urbanização, áreas de expansão agrícola e degradação ambiental (Jesus, 2023; Dias *et al.*, 2024). Ao integrar informações demográficas do IBGE, dados territoriais e séries históricas do MapBiomas, o aprendizado de máquina possibilita análises mais abrangentes sobre a relação entre mudanças na paisagem e fatores socioeconômicos. Essa abordagem permite compreender como diferentes fatores interagem no espaço geográfico.

3.2. Aprendizado de máquina e análise espacial: potencialidades para o estudo municipal

A configuração territorial dos municípios brasileiros, bem como sua classificação em unidades federativas e macrorregiões, segue critérios administrativos e geopolíticos historicamente construídos (IBGE, 2023). No entanto, as transformações contemporâneas — notadamente aquelas associadas ao uso e cobertura da terra — têm gerado dinâmicas que desafiam essas delimitações tradicionais (Aguiar; Baptista, 2023; Favero *et al.*, 2024). A crescente intensificação de atividades econômicas, como a expansão agropecuária, o avanço do desmatamento e a redução da superfície de água, revela a emergência de novos padrões territoriais que nem sempre encontram correspondência nas fronteiras institucionais existentes.

Nesse cenário, duas problemáticas ganham centralidade: a perda de cobertura florestal e o aumento da área agropecuária. Ambas operam para praticamente a totalidade do território nacional, em ritmos e intensidades distintos entre as regiões do país, impactando diretamente a biodiversidade, o equilíbrio climático e a sustentabilidade dos sistemas socioambientais locais (Dias *et al.*, 2024). A compreensão dessas dinâmicas exige abordagens analíticas capazes de

captar tanto a complexidade multivariada dos atributos municipais quanto a diversidade geográfica em que essas transformações se manifestam.

Dessa forma, este capítulo propôs a utilização de algoritmos de aprendizado de máquina com enfoque não supervisionado — mais especificamente, técnicas de *clusterização* — para a identificação de agrupamentos de municípios que compartilham características similares em termos de atributos territoriais, demográficos e ambientais. A ideia central é construir uma "comparação cartográfica" do território nacional, revelando padrões latentes que não se alinham, necessariamente, às divisões político-administrativas oficiais.

Além de identificar esses agrupamentos, foi feita a comparação dos clusters gerados com as regiões tradicionais brasileiras (macrorregiões e unidades da federação), de modo a avaliar em que medida os agrupamentos baseados em dados empíricos refletem — ou tensionam — as classificações territoriais estabelecidas. Com isso, buscou-se evidenciar se há coerência, superposição ou descompasso entre os agrupamentos gerados pelas características e as fronteiras políticas.

A proposta aqui delineada reforça o potencial do aprendizado de máquina como instrumento de leitura do espaço geográfico, não apenas pela capacidade de lidar com grandes volumes de dados, mas por permitir a revelação de estruturas ocultas e dinâmicas não lineares que escapam às análises tradicionais. Ao desmatamento às demais variáveis territoriais e demográficas, a análise contribui para uma compreensão mais integrada e crítica das transformações territoriais em curso no Brasil.

3.3 Aplicação de aprendizado de máquina na análise integrada de variáveis territoriais, demográficas e ambientais (LULC)

3.3.1 Análise Experimental de Técnicas de Clusterização e Classificação

A fim de identificar padrões latentes entre os municípios brasileiros com base em suas características territoriais, demográficas e ambientais, optou-se pela utilização de algoritmos de clusterização, pertencentes à classe de aprendizado de máquina não supervisionado. Essa abordagem permite agrupar unidades espaciais segundo similaridades nos atributos analisados, sem a necessidade de categorias predefinidas, o que se mostra particularmente útil diante da complexidade e diversidade do território nacional.

Com o objetivo de agrupar os municípios brasileiros a partir de características territoriais e ambientais padronizadas, foi conduzido um experimento envolvendo três algoritmos de *clusterização* amplamente utilizados na literatura: KMeans, DBSCAN e *Agglomerative Clustering*, combinados com três técnicas distintas de normalização de dados: StandardScaler, MinMaxScaler e RobustScaler. A base de dados que foi utilizada passou por tratamento prévio de dados ausentes e foi composta exclusivamente por variáveis numéricas.

A base de dados inclui indicadores de uso e cobertura da terra provenientes do MapBiomas (como proporções e variações de cobertura florestal, agropecuária, áreas não vegetadas e superfície de água), bem como indicadores populacionais e territoriais oriundos do IBGE (como extensão territorial, população absoluta e variações de extensão e população). Essas variáveis foram tratadas previamente, identificando correlações e colinearidades, após isso passando por diferentes processos de normalização (Z-score, MaxMin Scaler e RobustScaler), tratamento de valores ausentes e verificação de outliers, a fim de garantir a comparabilidade entre diferentes escalas e magnitudes.

A definição do número ideal de clusters foi realizada por meio da análise de índices de silhueta, curvas do cotovelo buscando identificar a qualidade dos agrupamentos formados (Gráfico 16). O método da silhueta avalia a qualidade dos agrupamentos medindo o quão bem cada ponto está posicionado dentro do seu próprio cluster em comparação com os clusters vizinhos. O coeficiente de silhueta varia de -1 a 1, sendo que valores mais próximos de 1 indicam uma boa separação entre os grupos e maior coesão interna. Já o método do cotovelo baseia-se na análise da inércia intra-cluster — ou seja, da soma das distâncias quadráticas entre os pontos e o centro do cluster — e busca identificar o ponto a partir do qual o acréscimo de novos clusters deixa de proporcionar ganhos significativos na compactação dos grupos.

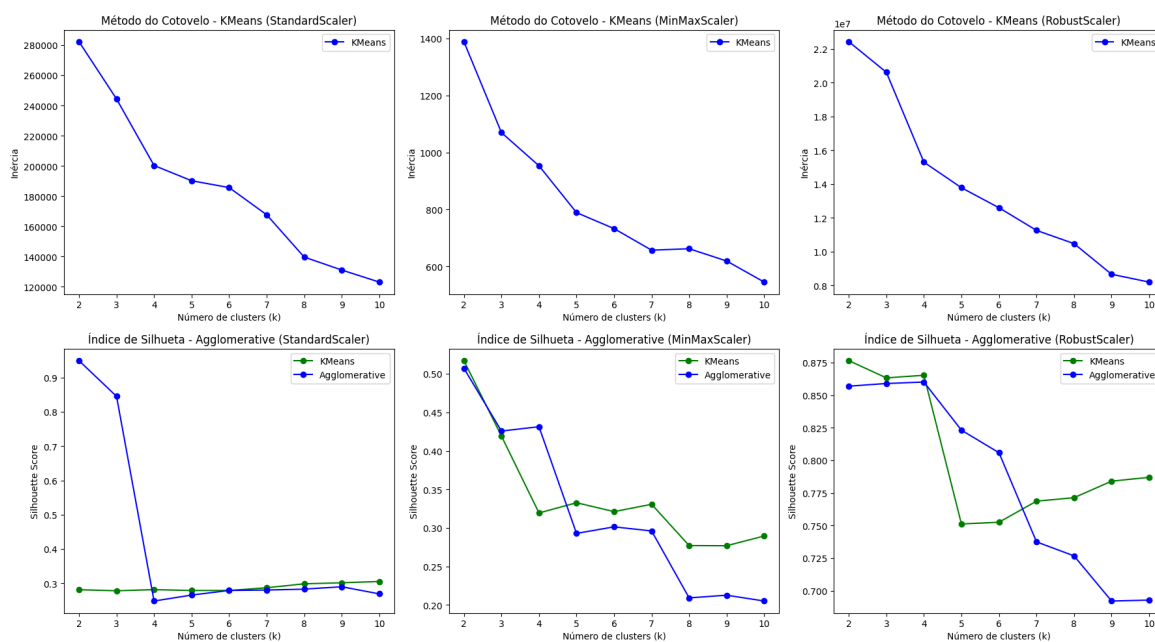


Gráfico 16. Testes de Cotovelo e Silhueta aplicados em diferentes normalizações de dados. Elaboração: o autor.

Cada combinação entre algoritmo e técnica de normalização foi avaliada com base na distribuição dos municípios entre os clusters resultantes. Abaixo são descritos os principais resultados observados:

- KMeans com StandardScaler e RobustScaler resultou em grande desequilíbrio na formação dos clusters, com a maioria dos municípios concentrados em poucos grupos e a presença de clusters residuais com poucos casos (menos de 5 municípios). Já com MinMaxScaler, o algoritmo apresentou uma distribuição mais equilibrada, com quatro grupos bem definidos, variando entre 273 e 2724 municípios por cluster. Esta combinação mostrou-se mais eficaz na representação das diferenças entre municípios (Tabela 4).

Tabela 4 – Distribuição de municípios nos clusters gerados pelo algoritmo KMeans, segundo a técnica de normalização aplicada

Cluster	StandardScaler	MinMaxScaler	RobustScaler
0	2219	1373	52
1	3323	2724	5508
2	25	1199	5
3	2	273	4
Total	5569	5569	5569

Tabela 4. Distribuição de municípios nos clusters gerados pelo algoritmo KMeans, segundo a técnica de normalização aplicada. Elaboração: o autor.

- O algoritmo DBSCAN apresentou desempenho altamente sensível à técnica de normalização adotada. Com StandardScaler e RobustScaler, a quase totalidade dos municípios foi classificada como *ruído* (rótulo -1), sugerindo que os parâmetros utilizados ($\text{eps} = 0.5$, $\text{min_samples} = 5$) não foram adequados sob essas escalas. Por outro lado, com a utilização do MinMaxScaler, o algoritmo foi capaz de identificar vários agrupamentos densos significativos, com cerca de 78 municípios sendo classificados como ruído e os demais distribuídos em cinco grupos distintos (Tabela 5).

Tabela 5 – Distribuição de municípios nos clusters gerados pelo algoritmo DBSCAN, segundo a técnica de normalização aplicada

Cluster	StandardScaler	MinMaxScaler	RobustScaler
-1 (ruído)	5538	78	5569
0	11	1172	0
1	5	1363	0
2	5	236	0
3	6	2710	0
4	4	5	0
5	0	5	0
Total	5569	5569	5569

Tabela 5. Distribuição de municípios nos clusters gerados pelo algoritmo DBSCAN, segundo a técnica de normalização aplicada. Elaboração: o autor.

- No caso do Agglomerative Clustering, padrões semelhantes ao KMeans foram observados. A combinação com StandardScaler e RobustScaler resultou novamente em agrupamentos com forte concentração em um ou dois clusters principais. A utilização do MinMaxScaler permitiu uma segmentação mais homogênea, com quatro grupos distribuídos de forma mais equilibrada entre os municípios (Tabela 6).

Tabela 6 – Distribuição de municípios nos clusters gerados pelo algoritmo Agglomerative Clustering, segundo a técnica de normalização aplicada

Cluster	StandardScaler	MinMaxScaler	RobustScaler
0	2910	1236	5556
1	2604	2720	6
2	53	1377	4
3	2	236	3
Total	5569	5569	5569

Tabela 6. Distribuição de municípios nos clusters gerados pelo algoritmo Agglomerative Clustering, segundo a técnica de normalização aplicada. Elaboração: o autor.

De forma geral, os resultados apontaram que a normalização MinMaxScaler foi a mais eficiente para os dados em questão, independentemente do algoritmo aplicado. Essa técnica, ao escalar os valores entre 0 e 1, possibilitou a melhor diferenciação entre os municípios, reduzindo o viés causado por variáveis com magnitudes discrepantes. Entre os algoritmos, KMeans e Agglomerative Clustering apresentaram os agrupamentos mais consistentes e interpretáveis, enquanto o DBSCAN se mostrou altamente sensível aos parâmetros e à normalização, exigindo ajustes mais refinados para aplicação em contextos de alta dimensionalidade e distribuição desigual de dados.

Com o elevado número de variáveis incluídas na base de dados dos municípios, o espaço amostral torna-se altamente dimensional, o que pode dificultar tanto a eficiência computacional quanto a qualidade dos algoritmos de agrupamento. Esse fenômeno, conhecido como "maldição da dimensionalidade", implica que, à medida que o número de dimensões aumenta, a distância entre os pontos tende a se tornar cada vez mais homogênea, prejudicando a capacidade dos métodos de clusterização de distinguir agrupamentos com clareza.

Para fins de interpretação, os agrupamentos obtidos foram posteriormente comparados com as classificações político-administrativas tradicionais, como as Unidades da Federação e macrorregiões brasileiras, verificando-se o grau de correspondência entre os agrupamentos analíticos e as delimitações institucionais. Assim, último passo desta etapa consistiu em comparar os agrupamentos obtidos por meio de técnicas de aprendizado de máquina com as divisões político-administrativas tradicionais do Brasil, como as macrorregiões (Norte, Nordeste, Centro-Oeste, Sudeste e Sul) e as unidades da federação (UFs). O objetivo foi avaliar em que medida os clusters gerados com base em atributos territoriais, demográficos e ambientais coincidem — ou se afastam — dessas divisões oficiais.

Um dos achados mais relevantes foi a constatação de que a formação dos clusters guarda maior correspondência com os biomas brasileiros do que com as divisões por estado ou região. Em outras palavras, municípios com características territoriais, populacionais e ambientais semelhantes tendem a ser agrupados no mesmo cluster, mesmo que estejam localizados em estados ou regiões diferentes. Por exemplo, municípios inseridos na Amazônia Legal, ainda que pertençam a diferentes UFs (como Pará, Amazonas, Maranhão e Mato Grosso), foram frequentemente agrupados em clusters similares, devido à predominância de cobertura florestal e baixa densidade populacional.

Essa observação revelou a potência das abordagens quantitativas e automatizadas para sugerir novas formas de regionalização do território brasileiro, com base em critérios multidimensionais, funcionais e ecológicos — em contraste com os critérios políticos tradicionais. Em alguns casos, os clusters gerados romperam completamente com as divisões de UFs, enquanto em outros, observaram-se transições graduais entre agrupamentos ao longo de fronteiras estaduais, o que reforça a ideia de continuidade espacial de determinadas características ambientais (Figura 13).

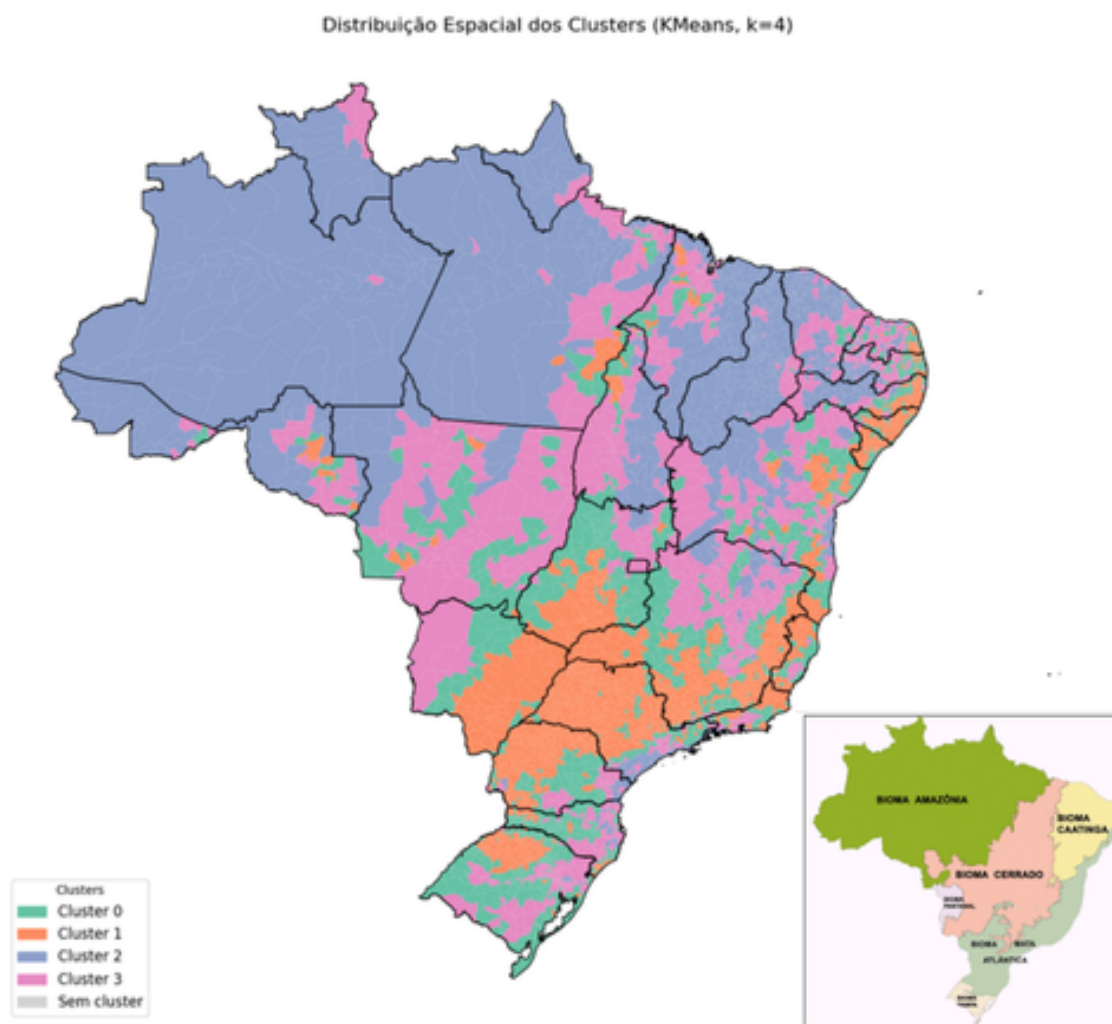


Figura 13. Mapa do Brasil gerado pelo algoritmo KMeans, considerando variáveis territoriais, populacionais e ambientais. Elaboração: o autor.

Para compreender melhor os fatores que mais influenciam a formação dos agrupamentos (clusters) identificados, foi utilizado o algoritmo *Random Forest Classifier* — um modelo de aprendizado de máquina supervisionado baseado em múltiplas árvores de decisão (Breiman, 2001). Na análise, o modelo foi treinado para prever o rótulo do cluster atribuído a cada município com base em seus atributos territoriais, demográficos e ambientais. Em seguida, foi calculada a importância relativa de cada variável. O gráfico gerado apresenta uma visão agregada da importância das variáveis utilizadas na formação dos agrupamentos, a partir da aplicação do algoritmo *Random Forest* aliado à abordagem de explicabilidade de modelos conhecida como *SHapley Additive exPlanations* (SHAP). Cada barra no gráfico representa uma variável explicativa do modelo, ordenada de acordo com sua importância média absoluta calculada a partir dos valores SHAP em todos os municípios analisados. Essa métrica indica, em termos médios, o quanto cada variável contribuiu para a diferenciação entre os clusters formados. O gráfico, portanto, permite identificar quais atributos territoriais, populacionais e ambientais tiveram maior

peso na separação dos agrupamentos, funcionando como uma ferramenta essencial para a interpretação dos critérios subjacentes à organização espacial proposta pelo modelo. Assim, o gráfico evidenciou que variáveis como a proporção de áreas agropecuária e florestais em 2023 foram as mais influentes na formação dos clusters, seguidas por estatísticas relacionadas à média e variação dessas mesmas categorias ao longo da série histórica.

Essa predominância de atributos ligados ao uso e cobertura da terra reforça o papel central da dimensão ambiental na estruturação dos agrupamentos, em consonância com os achados que apontam maior alinhamento dos clusters aos biomas do que às divisões político-administrativas tradicionais. A aplicação de técnicas de explicabilidade como SHAP, portanto, amplia a transparência do processo de modelagem e fortalece as análises interpretativas, permitindo compreender como diferentes dimensões territoriais interagem na construção de padrões espaciais complexos (Gráfico 17).




Gráfico 17. Lista de atributos mais importantes para clusterização via KMeans usando XAI (Shapley values).

Elaboração: o autor.

Outra possibilidade de interpretação e/ou explicabilidade do modelo é através da visualização da árvore de decisão gerada pelo modelo *Random Forest* (Figura 14) permite uma compreensão mais direta e interpretável das regras de decisão que o algoritmo utiliza para segmentar os dados. Ao representar graficamente os nós de decisão, variáveis utilizadas, valores de corte e resultados em cada folha, o *plot* da árvore revela como determinadas combinações de atributos — como porcentagem de cobertura florestal ou área da agropecuária — influenciam a alocação dos municípios nos diferentes clusters. Apesar do *Random Forest* ser composto por múltiplas árvores (formando um conjunto), a visualização de uma única árvore ou de uma árvore representativa auxilia na interpretação do comportamento do modelo, oferecendo *insights* sobre as relações hierárquicas entre variáveis e os critérios mais relevantes na formação dos agrupamentos. Esse tipo de visualização é particularmente útil em contextos exploratórios e analíticos, como o presente estudo, onde o objetivo principal não é a predição e sim a interpretação dos atributos.

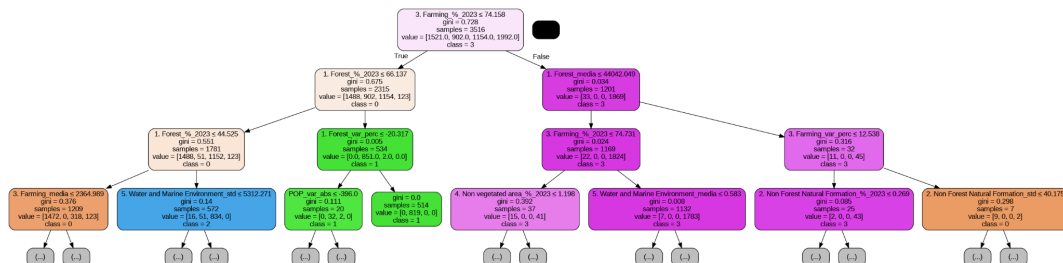


Figura 14. Árvore de decisão gerada pelo algoritmo de Floresta Aleatória. Elaboração: o autor.

A visualização da árvore de decisão gerada pelo modelo *Random Forest* oferece uma forma prática de interpretar os critérios que orientam a segmentação dos municípios, facilitando a compreensão das relações entre variáveis e os padrões subjacentes nos dados. Esse tipo de visualização complementa os resultados obtidos por meio de *clustering* e outras abordagens de aprendizado de máquina, proporcionando uma camada adicional de explicabilidade ao modelo, essencial para um entendimento mais profundo dos processos de agrupamento. No entanto, apesar das vantagens dessa abordagem, a aplicação de técnicas de IA na análise dos dados municipais enfrenta desafios consideráveis. Esses desafios não estão apenas ligados às limitações dos próprios algoritmos, mas também à qualidade dos dados, que são fundamentais para a construção de modelos robustos.

3.4 Avaliação das limitações e desafios do uso de IA na interpretação desses dados

Embora a inteligência artificial (IA) ofereça um enorme potencial para a análise municipal, sua aplicação prática enfrenta várias limitações e desafios. Estes desafios não apenas estão relacionados à capacidade de processamento dos modelos, mas também à qualidade, granularidade e disponibilidade dos dados utilizados. A eficácia dos modelos de aprendizado de máquina é altamente dependente da qualidade dos dados, e quaisquer inconsistências, lacunas ou imprecisões podem comprometer significativamente os resultados das análises.

Um dos principais obstáculos no uso de IA em áreas como a análise de dados territoriais e demográficos é a complexidade e diversidade dos dados que são integrados. A integração de fontes heterogêneas, como dados espaciais, temporais e tabulares, exige pré-processamento e harmonização cuidadosos. Esses dados, muitas vezes provenientes de diferentes fontes e escalas, podem apresentar formatos incompatíveis ou unidades de medida divergentes, o que torna o processo de integração mais desafiador.

Outro ponto crítico é a utilização de dados composicionais, que são frequentes em análises ambientais, geoespaciais e socioeconômicas. Dados composicionais são aqueles em que as variáveis representam frações ou porcentagens de um todo, cuja soma é sempre constante, como a soma das proporções de diferentes tipos de uso da terra ou de classes em censos demográficos. Trabalhar com dados composicionais exige cuidados especiais, pois a restrição de soma constante entre as variáveis cria interdependências entre elas. Por exemplo, ao aumentar a área de uma determinada classe, a área das outras classes diminui automaticamente, o que pode introduzir uma dependência que os modelos de IA podem não captar corretamente. Essas interdependências podem levar a resultados distorcidos, onde as variáveis parecem ter uma relação direta mais forte do que realmente possuem. Consequentemente, técnicas tradicionais de aprendizado de máquina, como a regressão linear, podem ter dificuldades para lidar com essa dependência, levando a potenciais problemas como o *overfitting* (ajustes excessivamente bons nos dados).

Além disso, a natureza dos dados temporais ou espaciais também impõe desafios, uma vez que as dinâmicas e padrões podem mudar ao longo do tempo ou variar significativamente em diferentes regiões. Essa variabilidade geoespacial e temporal exige modelos que sejam capazes de capturar essas mudanças dinâmicas, sem perder a capacidade de generalização. Modelos

convencionais podem ter dificuldades em lidar com a variabilidade temporal e espacial sem um rigoroso tratamento da autocorrelação e da heterogeneidade dos dados.

Outro desafio importante está relacionado à interpretação dos resultados dos modelos de IA. Embora as técnicas de aprendizado de máquina possam gerar resultados precisos, a interpretação desses resultados nem sempre é trivial, o que levanta preocupações sobre a transparência e a confiabilidade das análises (Ribeiro, 2022). Nesse contexto, o uso de *Explainable Artificial Intelligence* (XAI) torna-se crucial. A XAI visa aumentar a interpretabilidade dos modelos, fornecendo *insights* sobre como as decisões são tomadas, ajudando a identificar quais variáveis são mais influentes nas previsões e, portanto, permitindo uma melhor compreensão dos processos subjacentes. Sem essa explicabilidade, os resultados dos modelos podem ser vistos como “caixas pretas”, o que compromete a confiança na aplicação prática dessas ferramentas, especialmente em contextos onde a tomada de decisões impacta diretamente as políticas públicas ou a gestão ambiental.

Além disso, a aplicação de IA em grandes volumes de dados exige infraestrutura computacional robusta. O processamento de grandes quantidades de dados socioeconômicos de múltiplas fontes, demanda alto poder de processamento e armazenamento. Enquanto a escassez de dados de qualidade podem comprometer a robustez dos modelos. Em algumas dimensões, a diferença na disponibilidade de dados pode levar a vieses nos modelos, que, por sua vez, podem resultar em previsões imprecisas.

4 CONSIDERAÇÕES FINAIS

Neste capítulo, são discutidos os principais achados da pesquisa, bem como suas implicações para o entendimento das dinâmicas municipais brasileiras. A análise integrada utilizando IA/ML permite identificar padrões espaciais e temporais que podem aprimorar o planejamento territorial e a gestão pública. Além disso, foram comparadas diferentes abordagens metodológicas e discutidas as limitações dos modelos aplicados. Foram feitas reflexões sobre os desafios e oportunidades do uso de inteligência artificial na análise municipal, considerando questões como disponibilidade de dados, transparência dos modelos e aplicabilidade prática dos resultados.

3.1. Padrões e dinâmicas municipais identificadas a partir da análise integrada

A análise integrada dos dados municipais, que envolveu tanto abordagens estatísticas tradicionais quanto técnicas de aprendizado de máquina, revelou uma série de padrões e dinâmicas que ampliam o entendimento das complexas realidades territoriais e socioeconômicas dos municípios brasileiros.

O estudo revelou que a dimensão territorial dos municípios manteve-se em grande parte estável entre 2003 e 2023, com algumas variações significativas ao longo da fronteira entre as regiões Norte e Centro-Oeste. Essas mudanças podem refletir tanto o crescimento das áreas urbanas quanto o impacto de normativas estaduais e federais. Além disso, a variação da população entre municípios revelou padrões de concentração nas capitais e grandes centros urbanos, contrastando com o processo de dispersão observada nas cidades de médio porte, que passaram a desempenhar funções logísticas e administrativas.

Quando se considera o uso e a cobertura da terra, a análise revelou diferenças regionais claras. Municípios da região Norte, por exemplo, ainda apresentam grande cobertura florestal, especialmente na Amazônia Legal, ao passo que no Centro-Oeste e Nordeste, áreas de vegetação natural foram amplamente substituídas por atividades agropecuárias. Esse padrão foi corroborado pela análise das correlações entre áreas de uso agropecuário e florestal, com uma forte tendência de substituição de vegetação nativa, o que reflete as pressões externas e internas sobre os ecossistemas locais.

No contexto das políticas públicas, as tipologias tradicionais de classificação municipal, como aquelas baseadas em variáveis demográficas e de uso da terra, muitas vezes refletem abordagens estanques, baseadas em critérios rígidos que podem não captar as complexas dinâmicas territoriais e socioeconômicas em constante transformação. Tais tipologias, frequentemente derivadas de classificações como o tamanho populacional ou a distribuição geográfica, podem resultar em agrupamentos que não refletem adequadamente as realidades locais e as especificidades das regiões. O uso de aprendizado de máquina, por outro lado, oferece uma abordagem dinâmica e flexível para a criação de categorias municipais, baseadas em uma análise multidimensional que considera uma variedade de fatores interconectados. Ao empregar técnicas de *clusterização* e outros algoritmos de aprendizado não supervisionado, é possível identificar agrupamentos de municípios com características similares, sem depender das divisões políticas tradicionais, como as UFs ou as macrorregiões. Isso pode resultar em categorias mais precisas e menos discriminativas, possibilitando o desenvolvimento de políticas públicas mais adequadas à

realidade local, promovendo uma maior eficiência na alocação de recursos e na implementação de ações de desenvolvimento territorial

A aplicação de técnicas de clusterização e análise de aprendizado de máquina revelou *insights* adicionais e importantes sobre as dinâmicas municipais. Um dos achados mais significativos foi a identificação de que a formação dos clusters de municípios, baseados em características territoriais, populacionais e ambientais, correspondia mais aos biomas naturais do Brasil do que às divisões tradicionais por estado ou região. Municípios com características ambientais e de uso do solo semelhantes, mesmo que pertencentes a diferentes estados, foram agrupados em clusters com alta homogeneidade, demonstrando a força de abordagens baseadas em dados e em aprendizado de máquina para a identificação de padrões espaciais que fogem das divisões políticas-administrativas.

Por exemplo, municípios localizados na Amazônia Legal, independentemente de estarem em estados como Pará, Amazonas, Maranhão e Mato Grosso, apresentaram similaridades substanciais em termos de cobertura florestal e densidade populacional, o que levou à sua inclusão em *clusters* semelhantes. Este achado desafia as divisões tradicionais e sugere novas formas de regionalização com base em características ecológicas e funcionais.

A análise estatística proporciona uma base sólida para compreender as grandes desigualdades regionais e as dinâmicas históricas de ocupação do território. Já o aprendizado de máquina e a clusterização oferecem novas formas de entender o território a partir de padrões emergentes, permitindo não apenas a identificação de clusters, mas também o desenvolvimento de modelos preditivos que podem ser aplicados a futuras dinâmicas territoriais.

Essa integração de abordagens oferece um potencial significativo para aprimorar o planejamento territorial e a gestão pública. A capacidade de identificar padrões complexos e suas inter-relações, ao mesmo tempo em que se considera a realidade política e social de cada região, é fundamental para a formulação de políticas públicas mais eficazes e adaptadas às necessidades específicas de cada município. Além disso, a utilização de ferramentas como a inteligência artificial e aprendizado de máquina no contexto da análise territorial abre novas possibilidades para o mapeamento dinâmico de problemas socioambientais e a proposta de soluções mais eficientes e sustentáveis.

Portanto, a combinação de abordagens tradicionais com técnicas de IA/ML oferece um caminho promissor para aprimorar as limitações da análise territorial convencional e pode fornecer ferramentas mais precisas e eficientes para a gestão pública no Brasil. A articulação

deses métodos pode transformar a maneira como entendemos e intervimos nas dinâmicas municipais, com implicações diretas no desenvolvimento territorial e na redução das desigualdades históricas que marcam o país.

REFERÊNCIAS

ALBAHRI, A. S. et al. A systematic review of trustworthy artificial intelligence applications in natural disasters. **Computers and Electrical Engineering**, v. 118, p. 109409, 1 set. 2024. DOI 10.1016/j.compeleceng.2024.109409. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0045790624003379>. Acesso em: 21 de abr. 2025.

ALVES, M. A. S.; ANDRADE, O. M. de. Da “caixa-preta” à “caixa de vidro”: o uso da explainable artificial intelligence (XAI) para reduzir a opacidade e enfrentar o enviesamento em modelos algorítmicos. **Direito Público**, [S. l.], v. 18, n. 100, 2022. DOI 10.11117/rdp.v18i100.5973. Disponível em: <https://www.portaldeperiodicos.idp.edu.br/direitopublico/article/view/5973>. Acesso em: 21 abr. 2025.

AFUYE, G. A. *et al.* Global trend assessment of land use and land cover changes: A systematic approach to future research development and planning. **Journal of King Saud University - Science**, v. 36, n. 7, p. 103262, 1 ago. 2024. DOI 10.1016/j.jksus.2024.103262. Disponível: <https://www.sciencedirect.com/science/article/pii/S1018364724001745>. Acesso em: 21 de abr. 2025.

AGUIAR, B. DA S.; BAPTISTA, G. M. DE M. Aplicação de aprendizado de máquina para análise do crescimento urbano: o caso das regiões administrativas Ceilândia e Pôr do Sol no Distrito Federal. **Revista Brasileira de Geomática**, v. 11, n. 2, p. 465–487, 25 set. 2023. DOI 10.3895/rbgeo.v11n2.15936. Disponível em: <https://periodicos.utfpr.edu.br/rbgeo/article/view/15936>. Acesso em: 21 de abr. 2025.

AITCHISON, J. The Statistical Analysis of Compositional Data. **Journal of the Royal Statistical Society: Series B (Methodological)**, v. 44, n. 2, p. 139–160, 1982. DOI 10.1111/j.2517-6161.1982.tb01195.x. Disponível em: <https://onlinelibrary.wiley.com/doi/abs/10.1111/j.2517-6161.1982.tb01195.x>. Acesso em: 21 de abr. 2025.

ANDRADE, R. R. DE; CALDAS, A. V. S. Federalismo fiscal e transferências voluntárias da união aos municípios brasileiros. **Revista Políticas Públicas & Cidades**, v. 14, n. 1, p. e1449–e1449, 20 fev. 2025. DOI 10.23900/2359-1552v14n1-79-2025. Disponível em: <https://journalppc.com/RPPC/article/view/1449>. Acesso em: 21 de abr. 2025.

ARRETCHE, M.; MARQUES, E. Municipalização da saúde no Brasil: diferenças regionais, poder do voto e estratégias de governo. **Ciência & Saúde Coletiva**, v. 7, p. 455–479, 2002. DOI 10.1590/S1413-81232002000300006. Disponível em: <https://doi.org/10.1590/S1413-81232002000300006>. Acesso em 21 abr. 2025.

ARRETCHE, M. Federalismo e políticas sociais no Brasil: problemas de coordenação e autonomia. **São Paulo em Perspectiva**, v. 18, p. 17–26, jun. 2004. DOI <https://doi.org/10.1590/S0102-88392004000200003>. Disponível em: <https://www.scielo.br/j/spp/a/yrdb5VzhMD8wyrZDDS6WvvP>. Acesso em: 21 de abr. 2025.

_____. Federalismo e igualdade territorial: uma contradição em termos? **Dados**, v. 53, p. 587–620, 2010. DOI 10.1590/S0011-52582010000300003. Disponível em: <https://www.scielo.br/j/dados/a/Lrm7KQHYssvHZk6GmRrnf/?lang=pt>. Acesso em: 09 mar. 2025.

BARCELLOS, C. et al. Climate change, thermal anomalies, and the recent progression of dengue in Brazil. **Scientific Reports**, v. 14, n. 1, p. 5948, 11 mar. 2024. DOI 10.1038/s41598-024-56044-y. Disponível em: <https://www.nature.com/articles/s41598-024-56044-y>. Acesso em: 21 de abr. 2025.

BECKER, B. K. **Amazônia**. 4. ed. São Paulo: Ática. 1996. 112 p

_____. Novas territorialidades na Amazônia: desafio às políticas públicas. **Boletim do Museu Paraense Emílio Goeldi. Ciências Humanas**, v. 5, p. 17–23, abr. 2010. DOI 10.1590/S1981-81222010000100003. Disponível em: <https://www.scielo.br/j/bgoeldi/a/d4vc5x595k5mJZfnMNNPKTs/>. Acesso em: 21 de abr. 2025.

_____. A Geografia e o Resgate da Geopolítica. **Espaço Aberto**, v. 2, n. 1, p. 117–150, 2012. Disponível em: <https://dialnet.unirioja.es/servlet/articulo?codigo=5301614>. Acesso em: 21 de abr. 2025.

BERRAR, D. Cross-Validation. In: RANGANATHAN, S., GRIBSKOV, M., NAKAI, K.; CHRISTIAN SCHÖNBACH, C., (Eds.), **Reference Module in Life Sciences Encyclopedia of Bioinformatics and Computational Biology**, Vol. 1, Elsevier, Amsterdam, 542-545. DOI 10.1016/B978-0-12-809633-8.20349-X. Disponível em: <https://www.sciencedirect.com/reference/title/53527421>. Acesso em: 21 de abr. 2025.

BRASIL. **Constituição (1988)**. *Constituição da República Federativa do Brasil de 1988*. Brasília, DF: Presidência da República, 2024. Disponível em: http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm. Acesso em: 21 abr. 2025.

_____. Lei nº 6.634, de 2 de maio de 1979. Dispõe sobre a Faixa de fronteira e dá outras providências. Brasília: Distrito Federal. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l6634.htm. Acesso em: 25 de mar. de 2025.

BREMAEKER, F. E. Os novos municípios: surgimento, problemas e soluções. **Revista de Administração Municipal**, v. 40, n. 206, p. 88-99, jan./mar. 1993. Disponível em: http://www.oim.tmmunicipal.org.br/abre_documento.cfm?arquivo=_repositorio/_oim/_documentos/C2E2202D-B55A-5493-9695F0DF427A6F0618032015103318.pdf&i=2722. Acesso em: 21 de abr. 2025.

BREIMAN, L. Random Forests. **Machine Learning**, v. 45, n. 1, p. 5–32, 1 out. 2001. DOI 10.1023/A:1010933404324. Disponível em: <https://doi.org/10.1023/A:1010933404324>. Acesso em: 22 de abr. 2025.

CÔRTEZ, J. C.; D'ANTONA, Á. DE O. Dinâmicas no uso e cobertura da terra: perspectivas e desafios da Demografia. **Revista Brasileira de Estudos de População**, v. 31, p. 191–210, jun. 2014. DOI 10.1590/S0102-30982014000100011. Disponível em: <https://www.scielo.br/j/rbepop/a/ZyfwxYfpy395Ghgq95B4zzF/>. Acesso em: 18 de abr. 2025.

CHIKHALKAR, A. et al. A Data Pipeline Concept for Digitizing Services in Small and Medium-Sized Companies. **JOIV : International Journal on Informatics Visualization**, v. 9, n. 1, p. 333–341, 31 jan. 2025. DOI 10.62527/joiv.9.1.3796. Disponível em: <http://joiv.org/index.php/joiv/article/view/3796>. Acesso em: 21 de abr. 2025.

CNM – Confederação Nacional de Municípios. Crise Fiscal nos Municípios Brasileiros. Brasília: 2024. Disponível em:

https://cnm.org.br/storage/biblioteca/2024/Estudos_tecnicos/202405_ET_CrisenosMunicipios_2023_.pdf. Acesso em: 9 mar. 2025.

DIAS, F. *et al.* Predicting the pulse of the Amazon: Machine learning insights into deforestation dynamics. **Journal of Environmental Management**, v. 362, p. 121359, 1 jun. 2024. DOI 10.1016/j.jenvman.2024.121359. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0301479724013458>. Acesso em: 21 de abr. 2025.

DO CARMO, R. L.; TEIXEIRA, A. C. C. COVID-19 e Precariedade Urbana. *In:* Valencio, N.; Oliveira, C. M. (Org.). **COVID-19: crises entremeadas no contexto de pandemia (antecedentes, cenários e recomendações)**. São Carlos: UFSCar/CPOI, 2020. cap. 10, p. 151-164.

ESCOVEDO, T.; KOSHIYAMA, A. **Introdução à Data Science: algoritmos e Machine Learning e métodos de análise**. Casa do Código, 2020. 334. p

FAVERO, I. *et al.* Aprendizado de máquina aplicado no mapeamento do uso e cobertura do solo de assentamentos de reforma agrária no Acre. **Revista Tamoios**, v. 20, n. 2, p. 248–265, 22 jul. 2024. DOI 10.12957/tamoios.2024.77078. Disponível em: <https://www.e-publicacoes.uerj.br/tamoios/article/view/77078>. Acesso em: 21 de abr. 2025.

FERREIRA, R. Da Inteligência Artificial à Inteligência Geográfica, *InforGeo*, nº 27. v. 27, p. 8–18, 25 fev. 2025.

FRANCA ROCHA, W. J. S. *et al.* Mapping Burned Area in the Caatinga Biome: Employing Deep Learning Techniques. **Fire**, v. 7, n. 12, p. 437, dez. 2024. DOI 10.3390/fire7120437. Disponível em: <https://www.mdpi.com/2571-6255/7/12/437>. Acesso em: 21 de abr. 2025.

FREITAS, C. M. DE; BARCELLOS, C. Desastre no Rio Grande do Sul, Brasil: crise climática, resposta do Sistema Único de Saúde e desafios dos novos tempos. **Cadernos de Saúde Pública**, v. 40, p. e00114424, 13 jan. 2025. DOI 10.1590/0102-311XPT114424. Disponível em: <https://www.scielo.org/article/csp/2024.v40n11/e00114424/pt/#>. Acesso: 21 de abr. 2025.

FIALHO, M. *et al.* **Análise espaço-temporal das transições da floresta atlântica no contexto do sudeste usando o Mapbiomas**. VII Jornada de Geotecnologias do Estado do Rio de Janeiro (JGEOTEC 2024). 2024. Disponível em: https://www.researchgate.net/profile/Felipe-Amaral-4/publication/387948999_ANALISE_ESPACO-TEMPORAL_DAS_TRANSICOES_DA_FLORESTA_ATLANTICA_NO_CONTEXTO_DO_SUDESTE_USANDO_O_MAPBIOMAS/links/6783d9e54f26bf2ca598ade1/ANALISE-ESPACO-TEMPORAL-DAS-TRANSICOES-DA-FLORESTA-ATLANTICA-NO-CONTEXTO-DO-SUDESTE-USANDO-O-MAPBIOMAS.pdf. Acesso em: 11 de mar. 2025.

DA SILVA, F. R., *et al.* O arco do desmatamento na amazônia: uma análise espacial do papel das rodovias como vetor do desflorestamento. *In:* SOUTO, R. D. *et al.* **Anais da VII Jornada de Geotecnologias do Estado do Rio de Janeiro (JGEOTEC 2024)**. [s.l.] Rio de Janeiro: Editora IVIDES, 2024.

GOMES, N.; MATOS, R.; LOBO, C. Classificação demográfica e caracterização geográfica dos municípios de pequeno porte do Sudeste brasileiro. **Revista da ANPEGE**, v. 16, n. 30, p. 55–74, 2020. DOI 10.5418/ra2020.v16i30.9345. Disponível em: <https://ojs.ufgd.edu.br/anpege/article/view/9345>. Acesso em 21 de abr. 2025.

GOTELLI, N. J. *et al.* **Princípios de Estatística em Ecologia**. 1ª ed. Porto Alegre: Artmed. 2010. 527 p.

HOINATSKI, C. Além das divisas e fronteiras: o sulmassp como ferramenta de integração da segurança pública para o enfrentamento ao crime organizado. **Revista Ibero-Americana de Humanidades, Ciências e Educação**, v. 11, n. 2, p. 158–189, 1 fev. 2025. DOI 10.51891/rease.v11i2.18092. Disponível em:

<https://periodicorease.pro.br/rease/article/view/18092>. Acesso em: 21 de abr. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. Evolução da divisão territorial do Brasil: 1872 - 2010. Rio de Janeiro: IBGE, 2011. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=255077>. Acesso em: 21 de abr. 2025.

_____. Divisão Territorial Brasileira 2023. Rio de Janeiro: IBGE, 2023a. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/23701-divisao-territorial-brasileira.html>. Acesso em: 20 fev. 2025.

_____. Proposta metodológica para classificação dos espaços do rural, do urbano e da natureza no Brasil. Rio de Janeiro: IBGE, 2023b. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/tipologias-do-territorio/15790-classificacao-rural-e-urbana.html>. Acesso em 21 de abr. de 2025.

_____. Censo Demográfico 2022: Resultados Preliminares. Rio de Janeiro: IBGE, 2023c. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/populacao/22827-censo-demografico-2022.html?=&t=o-que-e>. Acesso em: 20 fev. 2025.

_____. Pesquisa de Informações Básicas Municipais: MUNIC 2023. Rio de Janeiro: IBGE, 2023d. Disponível em: <https://www.ibge.gov.br/estatisticas/sociais/educacao/10586-pesquisa-de-informacoes-basicas-municipais.html>. Acesso em: 20 fev. 2025.

_____. Municípios limítrofes. Rio de Janeiro: IBGE, 2023e. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/42224-municipios-limitrofes.html?=&t=o-que-e>. Acesso em: 17 de mar. de 2025.

_____. Atualização dos Mapas Municipais. Rio de Janeiro: IBGE, 2023f. Disponível em: <https://www.ibge.gov.br/geociencias/cartas-e-mapas/mapas-municipais/27437-atualizacao-dos-mapas-municipais.html>. Acesso em: 21 mar. 2025.

_____. Municípios da faixa de fronteira e cidades gêmeas. Rio de Janeiro: IBGE, 2023g. Disponível em: <https://www.ibge.gov.br/geociencias/organizacao-do-territorio/estrutura-territorial/24073-municipios-da-faixa-de-fronteira.html?=&t=o-que-e>. Acesso em: 24 de mar. 2025.

IBGE – Instituto Brasileiro de Geografia e Estatística. Malha Municipal Digital e Áreas Territoriais 2023: Notas metodológicas 01/2024 informações técnicas e legais para utilização dos dados publicados. Rio de Janeiro: IBGE, 2024. Disponível em: <https://biblioteca.ibge.gov.br/visualizacao/livros/liv102152.pdf>. Acesso em: 07 mar. 2025.

IBM – . O que é engenharia de funcionalidades? Disponível em: <https://www.ibm.com/br-pt/think/topics/feature-engineering>. Acesso: em 14 mar. 2025.

KLERING, L. R.; KRUEL, A. J.; STRANZ, E. Os pequenos municípios do Brasil – uma análise a partir de índices de gestão. **Análise – Revista de Administração da PUCRS**, v. 23, n. 1, p. 31–44, 2012. Disponível em: <https://revistaseletronicas.pucrs.br/face/article/view/11433>. Acesso em: 21 de abr. 2025.

LIMA, D. V. de. **Espaço local em perspectiva: os limites e as possibilidades dos pequenos municípios no federalismo brasileiro**. Brasília: CNM, 2023. 174. p. Disponível em: https://cnm.org.br/storage/biblioteca/2023/Livros/2023_LIV_JUR_Espaco_Local_Perspectiva.pdf. Acesso em: 21 de abr. 2025.

LOPES, *et al.* Diagnóstico da fragmentação de formações florestais e savânicas na bacia hidrográfica do rio Paracatu. **Nativa**, [S. l.], v. 13, n. 1, p. 20–30, 2025. DOI [10.31413/nat.v13i1.18335](https://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/view/18335). Disponível em: <https://periodicoscientificos.ufmt.br/ojs/index.php/nativa/article/view/18335>. Acesso em: 11 mar. 2025.

LUNDBERG, S.; LEE, S.-I. **A Unified Approach to Interpreting Model Predictions**. arXiv, , 25 nov. 2017. Disponível em: <http://arxiv.org/abs/1705.07874>>. Acesso em: 15 mar. 2025.

MAIA, A. G.; QUADROS, W. J. DE. Tipologia municipal de classes sociocupacionais: uma nova dimensão para análise das desigualdades territoriais no Brasil. **Revista de Economia e Sociologia Rural**, v. 47, p. 389–418, jun. 2009. DOI 10.1590/S0103-20032009000200004. Disponível em: <https://www.scielo.br/j/resr/a/PpPX9PT5L8xsVM3T9MwsNMj/?lang=pt>. Acesso em: 21 de abr. 2025.

MAGALHÃES, J. C. Emancipação político-administrativa de municípios no Brasil. *In*: **Dinâmica dos municípios**. Carvalho, A. X. Y.; Albuquerque, C. W.; Mota, J. A.; Piancastelli, M. (orgs.). Brasília: Ipea, 2007. 326 p.

MAPBIOMAS – Coleção 9 da Série Anual de Mapas de Cobertura e Uso da Terra do Brasil. Disponível em: <https://brasil.mapbiomas.org/codigos-de-legenda/>. Acesso em: 14 de mar. 2025.

MCKIGHT, P. E.; NAJAB, J. Kruskal-Wallis Test. Em: WEINER, I. B.; CRAIGHEAD, W. E. (Eds.). **The Corsini Encyclopedia of Psychology**. 1. ed. [s.l.] Wiley, 2010. p. 1–1.

MONTEIRO, A. M. V.; ANAZAWA, T. M.; OLIVEIRA, G. C. 'O Longo Amanhecer': as crises sanitária e do planejamento a partir da covid-19 na metrópole do vale do paraíba e litoral norte. *In*: Valencio, N.; Oliveira, C. M. (Orgs.). **COVID-19: crises entremeadas no contexto de pandemia (antecedentes, cenários e recomendações)**. São Carlos: UFSCar/CPOI, 2020. cap. 14, p. 212-234.

NAMBIAR, A.; MUNDRA, D. An Overview of Data Warehouse and Data Lake in Modern Enterprise Data Management. **Big Data and Cognitive Computing**, v. 6, n. 4, p. 132, dez. 2022. DOI 10.3390/bdcc6040132. Disponível em: <https://www.mdpi.com/2504-2289/6/4/132>. Acesso em: 21 de abr. 2025.

OLIVEIRA, F. M. de; TAVARES, R. G.; ARRUDA, V. C. M.; ANDRADE, J. da S. C. de O.; MORAIS, D. P.; MORAES, A. S. Geoprocessamento aplicado à avaliação de Áreas de Preservação Permanente de nascentes inseridas na área de influência do Complexo Portuário de Suape: Geoprocessing applied to the evaluation of Permanent Preservation Areas of springs located in the area of influence of the Suape Port Complex. *Revista de Geociências do Nordeste*, [S. l.], v. 11, n. 1, p. 423–438, 2025. DOI 10.21680/2447-3359.2025v11n1ID37540. Disponível em: <https://periodicos.ufrn.br/revistadoregne/article/view/37540>. Acesso em: 11 mar. 2025.

Paloni, N. A. **O Estudo de Viabilidade Municipal e seu impacto no desenvolvimento nacional**. 2008. 147 p. Dissertação (Mestrado em Filosofia do Direito e do Estado) - Universidade Pontifícia Católica de São Paulo, São Paulo. 2008.

PAULA, E. A. DE; CORREIA, D.; VALENCIO, N. Entre desastres catastróficos e mobilidades controladas: das idas e vindas de camponeses brasileiros à chegada dos imigrantes haitianos no “reino deste mundo amazônico”. **Contemporânea - Revista de Sociologia da UFSCar**, v. 3, n. 1, p. 45, 12 jul. 2013. Disponível em: <https://www.contemporanea.ufscar.br/index.php/contemporanea/article/view/118> . Acesso em: 21 de abr. 2025.

PERA, C. K. L.; BUENO, L. M. DE M. Revendo o uso de dados do IBGE para pesquisa e planejamento territorial: reflexões quanto à classificação da situação urbana e rural. **Cadernos Metrópole**, v. 18, p. 722–742, dez. 2016. DOI 10.1590/2236-9996.2016-3705. Disponível em: <https://www.scielo.br/j/cm/a/q6McCKhzM9dSK3KyOPyKHCO/>. Acesso em: 21 de abr. 2025.

PERES, R. B. COVID-19 em Cidades Médias Paulistas: reflexos, cenários e perspectivas. *In*: Valencio, N.; Oliveira, C. M. (Org.). **COVID-19: crises entremeadas no contexto de pandemia (antecedentes, cenários e recomendações)**. São Carlos: UFSCar/CPOI, 2020. cap. 16, p. 245-260.

PERETTA, C. S.; ALMEIDA, M. R. R. O PAPEL DOS MUNICÍPIOS BRASILEIROS NO PLANEJAMENTO AMBIENTAL E NA GESTÃO DOS RECURSOS HÍDRICOS: COMPETÊNCIAS, DESAFIOS E PERSPECTIVAS. **Perspectivas em Políticas Públicas**, [S. l.], v. 18, n. 35, p. 139–165, 2025. DOI: 10.36704/ppp.v18i35.8868. Disponível em: <https://revista.uemg.br/index.php/revistapp/article/view/8868>. Acesso em: 21 fev. 2025.

RABESCHINI, G. *et al.* Choosing fit-for-purpose biodiversity impact indicators for agriculture in the Brazilian Cerrado ecoregion. **Nature Communications**, v. 16, n. 1, p. 1799, 20 fev. 2025. DOI 10.1038/s41467-025-57037-9. Disponível em: <https://www.nature.com/articles/s41467-025-57037-9>. Acesso em: 21 de abr. 2025.

RESENDE, A. J. C. Autonomia municipal e lei orgânica. **Cadernos da Escola do Legislativo**, Belo Horizonte: Assembleia Legislativa do Estado de Minas Gerais, v. 10, n. 15, p. 7-42, jan./dez. 2008. Disponível em: <https://dspace.almg.gov.br/bitstream/11037/1266/3/0001266.pdf>. Acesso em 21 de abr. 2025.

RIBEIRO, R. S. Inteligência artificial, Direito e equidade algorítmica: discriminações sociais em modelos de machine learning para a tomada de decisão. **Revista de Informação Legislativa**, v. 59, n. 236, p. 29–53, 2022. Disponível em: Disponível em: https://www12.senado.leg.br/ril/edicoes/59/236/ril_v59_n236_p29. Acesso em: 21 mar. 2025.

ROSARIO, I. T. da S.; SANTOS FILHO, A. M. Transformações urbanas em Lauro de Freitas (BA): uma análise da evolução das áreas urbanizadas através do mapbiomas . *Revista Territorium Terram*, [S. l.], v. 8, n. 14, p. 139–151, 2025. Disponível em: https://periodicos.ufsj.edu.br/territorium_terram/article/view/5550. Acesso em: 21 abr. 2025.

SANTANA, K. V. DE S. DE *et al.* Space–Time Analysis of the COVID-19 Pandemic and Its Relationship with Socioeconomic and Demographic Variables in the Metropolitan Region of São Paulo, Brazil. **ISPRS International Journal of Geo-Information**, v. 13, n. 11, p. 397, nov. 2024. DOI 10.3390/ijgi13110397. Disponível em: <https://www.mdpi.com/2220-9964/13/11/397>. Acesso: 21 de abr. 2025.

SANTOS, M. **Metamorfoses do espaço habitado: fundamentos teóricos e metodológicos da geografia**. São Paulo: Hucitec, 1996.

_____. **Espaço e método**. São Paulo: Nobel, 1997.

_____. **A urbanização brasileira**. São Paulo: EDUSP, 2005.

SANTOS, M.; SILVEIRA, M. L. **O Brasil: território e sociedade no início do século XXI**. Rio de Janeiro: Editora Record, 2001.

SANTOS, J. B. DOS. A importância das informações estatísticas do censo do IBGE 2022 para a gestão das políticas públicas no município de Irará (Bahia). **RECIMA21 - Revista Científica Multidisciplinar - ISSN 2675-6218**, v. 6, n. 3, p. e636240, 1 mar. 2025. DOI 10.47820/recima21.v6i3.6240. Disponível em: <https://recima21.com.br/index.php/recima21/article/view/6240>. Acesso em: 21 de abr. 2025.

SANTOS, T. S. dos.; SANTOS NETO, J. E. dos.; SOUZA, E. M. de 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, [S. l.]**, v. 14, n. 2, p. e0514248115, 2025. DOI: 10.33448/rsd-v14i2.48115. Disponível em: <https://rsdjournal.org/index.php/rsd/article/view/48115>. Acesso em: 11 mar. 2025.

SAUER, S. Questão eco-agrária: extrativismo agrário, mudanças climáticas e desmatamento no Brasil. **Revista NERA**, v. 27, p. e10185, 6 set. 2024. DOI doi.org/10.47946/rnera.v27i2.10185. Disponível em: <https://www.scielo.br/j/nera/a/bFwSNxnJPT3mssTDGYBLz3C/>. Acesso em: 21 de abr. 2025.

SILVA, L. F. DE O. Territorial management of metropolitan regions in reach of urban development and reduction of regional disparities in Brazil/ A gestão territorial das regiões metropolitanas no alcance do desenvolvimento urbano e na redução das disparidades regionais no Brasil. **Direito da Cidade**, v. 7, n. 3, p. 940–960, 1 set. 2015.

SOUZA, A. Emancipações distritais e criação de municípios no Brasil após a constituição federal de 1988. **Revista Geomae - Geografia Meio Ambiente e Ensino**, v. 6, n. 1, p. 50–72, 2015. Disponível em: <https://periodicos.unespar.edu.br/geomae/article/view/5828>. Acesso em: 21 de abr. 2025.

SOUZA, C. M. *et al.* 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, jan. 2020. DOI 10.3390/rs12172735. Disponível em: <https://www.mdpi.com/2072-4292/12/17/2735>. Acesso em: 21 de abr. 2025.

SOUZA, C. M. *et al.* Amazon severe drought in 2023 triggered surface water loss. **Environmental Research: Climate**, v. 3, n. 4, p. 041002, out. 2024. DOI 10.1088/2752-5295/ad7c71. Disponível em: <https://iopscience.iop.org/article/10.1088/2752-5295/ad7c71>. Acesso em: 21 de abr. 2025.

SPOSITO, E. Proposições teóricas e metodológicas para o estudo das cidades pequenas. **Revista Univap**, v. 30, n. 69, 18 dez. 2024. DOI 10.18066/revistaunivap.v30i69.4670. Disponível em: <https://revista.univap.br/index.php/revistaunivap/article/view/4670>. Acesso em: 21 de abr. 2025.

TASNUVA, A. *et al.* Developing a disaster risk index for coastal communities in southwest Bangladesh: Shifting from data-driven models to holistic approaches. **Ecological Indicators**, v. 166, p. 112381, 1 set. 2024. DOI 10.1016/j.ecolind.2024.112381. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1470160X24008380>. Acesso em: 21 de abr. 2025.

UN-HABITAT. *Cities and climate action: World cities report 2024*. Nairobi: United Nations Human Settlements Programme, 2024. Disponível em: <https://unhabitat.org/world-cities-report-2024>. Acesso em: 21 abr. 2025.

VANWEY, L. K.; D'ANTONA, Á. O.; BRONDÍZIO, E. S. Household demographic change and land use/land cover change in the Brazilian Amazon. **Population and Environment**, v. 28, n. 3, p. 163–185, 1 jan. 2007. DOI 10.1007/s11111-007-0040-y. Disponível em: <https://doi.org/10.1007/s11111-007-0040-y>. Acesso: 19 de abr. 2025.

VELASCO, J. C. De muros intransponíveis a fronteiras transitáveis. **REMHU: Revista Interdisciplinar da Mobilidade Humana**, v. 27, n. 57, p. 159–174, dez. 2019. DOI 10.1590/1980-85852503880005710. Disponível em: http://www.scielo.br/scielo.php?script=sci_arttext&pid=S1980-85852019000300159 & tlng=pt. Acesso em: 21 de abr. 2025.

VILAR, L. *et al.* Multitemporal Modelling of Socio-Economic Wildfire Drivers in Central Spain between the 1980s and the 2000s: Comparing Generalized Linear Models to Machine Learning Algorithms. **PLOS ONE**, v. 11, n. 8, p. e0161344, 24 ago. 2016. DOI 10.1371/journal.pone.0161344. Disponível em: <https://dx.plos.org/10.1371/journal.pone.0161344>. Acesso em: 21 de abr. 2025.

WANG, J. *et al.* Machine learning in modelling land-use and land cover-change (LULCC): Current status, challenges and prospects. **Science of The Total Environment**, v. 822, p. 153559, 2022. DOI 10.1016/j.scitotenv.2022.153559. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0048969722006519>. Acesso em: 21 de abr. 2025.

ZAGALLO, S. A. Sustentabilidade Municipal: orientações para a gestão ambiental. Coleção gestão pública municipal: XXIII Marcha a Brasília em defesa dos municípios – Edição 2022. Brasília: 2022. Disponível em: https://cnm.org.br/storage/biblioteca/2022/Livros/2022_LIV_MAMB_Sustentabilidade_municipal_orientacoes_gestao_ambiental.pdf. Acesso em: 21 de abr. 2025.

ANEXOS

Anexo 1. Códigos das classes da legenda da Coleção 9 do MapBiomias Brasil.

 MAPBIOMIAS BRASIL		Códigos das classes da legenda da Coleção 9 do MapBiomias Brasil		
COLEÇÃO 9 - CLASSES	COLLECTION 9 - CLASSES	Code ID	Hexacode Number	Color ID
1. Floresta	1. Forest	1	#1f8d49	
1.1 Formação Florestal	1.1. Forest Formation	3	#1f8d49	
1.2. Formação Savânica	1.2. Savanna Formation	4	#7dc975	
1.3. Mangue	1.3. Mangrove	5	#04381d	
1.4. Floresta Alagável	1.4 Floodable Forest	6	#007785	
1.5. Restinga Arbórea	1.5. Wooded Sandbank Vegetation	49	#02d659	
2. Vegetação Herbácea e Arbustiva	2. Herbaceous and Shrubby Vegetation	10	#d6bc74	
2.1. Campo Alagado e Área Pantanosa	2.1. Wetland	11	#519799	
2.2. Formação Campestre	2.2. Grassland	12	#d6bc74	
2.3. Apicum	2.3. Hypersaline Tidal Flat	32	#fc8114	
2.4. Afloramento Rochoso	2.4. Rocky Outcrop	29	#ffaa5f	
2.5. Restinga Herbácea	2.5. Herbaceous Sandbank Vegetation	50	#ad5100	
3. Agropecuária	3. Farming	14	#ffefc3	
3.1. Pastagem	3.1. Pasture	15	#edde8e	
3.2. Agricultura	3.2. Agriculture	18	#E974ED	
3.2.1. Lavoura Temporária	3.2.1. Temporary Crop	19	#C27BA0	
3.2.1.1. Soja	3.2.1.1. Soybean	39	#f5b3c8	
3.2.1.2. Cana	3.2.1.2. Sugar cane	20	#db7093	
3.2.1.3. Arroz	3.2.1.3. Rice	40	#c71585	
3.2.1.4. Algodão (beta)	3.2.1.4. Cotton (beta)	62	#ff69b4	
3.2.1.5. Outras Lavouras Temporárias	3.2.1.5. Other Temporary Crops	41	#f54ca9	
3.2.2. Lavoura Perene	3.2.2. Perennial Crop	36	#d082de	
3.2.2.1. Café	3.2.2.1. Coffee	46	#d68fe2	
3.2.2.2. Citrus	3.2.2.2. Citrus	47	#9932cc	
3.2.2.3. Dendê	3.2.2.3. Palm Oil	35	#9065d0	
3.2.2.4. Outras Lavouras Perenes	3.2.2.4. Other Perennial Crops	48	#e6ccff	
3.3. Silvicultura	3.3. Forest Plantation	9	#7a5900	
3.4. Mosaico de Usos	3.4. Mosaic of Uses	21	#ffefc3	
4. Área não Vegetada	4. Non vegetated area	22	#d4271e	
4.1. Praia, Duna e Areal	4.1. Beach, Dune and Sand Spot	23	#ffa07a	
4.2. Área Urbanizada	4.2. Urban Area	24	#d4271e	
4.3. Mineração	4.3. Mining	30	#9c0027	
4.4. Outras Áreas não Vegetadas	4.4. Other non Vegetated Areas	25	#db4d4f	
5. Corpo D'água	5. Water	26	#2532e4	
5.1 Rio, Lago e Oceano	5.1. River, Lake and Ocean	33	#2532e4	
5.2 Aquicultura	5.2. Aquaculture	31	#091077	
6. Não observado	6. Not Observed	27	#ffffff	

Autor: MapBiomias (2023).

APÊNDICES

Apêndice 1. Estatística descritiva variáveis de extensão territorial do País

Estatística Descritiva						
	AREA_2003_KM2	AREA_2012_KM2	AREA_2023_KM2	PROP_VAR_2003_2012	PROP_VAR_2012_2023	PROP_VAR_2003_2023
N	5560	5565	5570	5560	5565	5560
Omisso	10	5	0	10	5	10
Mediana	415	416	418	3.02e-6	0.00	3.38e-6
Variância	3.17e+7	3.16e+7	3.14e+7	0.00740	0.00347	0.0101
Mínimo	2.86	3.56	3.56	-0.611	-0.536	-0.613
Máximo	159684	159534	159533	2.61	1.72	2.59

Apêndice 2. Estatística descritiva de variáveis de extensão territorial por Macrorregiões

Estatística Descritiva							
	Macrorregião	AREA_2003_KM2	AREA_2012_KM2	AREA_2023_KM2	PROP_VAR_2003_2012	PROP_VAR_2012_2023	PROP_VAR_2003_2023
N	Norte	449	449	450	449	449	449
	Nordeste	1792	1794	1794	1792	1794	1792
	Sudeste	1668	1668	1668	1668	1668	1668
	Sul	1188	1188	1191	1188	1188	1188
	Centro-oeste	463	466	467	463	466	463
Omisso	Norte	1	1	0	1	1	1
	Nordeste	2	0	0	2	0	2
	Sudeste	0	0	0	0	0	0
	Sul	3	3	0	3	3	3
	Centro-oeste	4	1	0	4	1	4
Mediana	Norte	2907	2944	2923	5.17e-6	0.00	5.81e-7
	Nordeste	436	438	442	8.61e-6	0.00	1.15e-5
	Sudeste	327	327	328	1.55e-4	0.00	1.54e-4
	Sul	275	275	272	0.00	0.00	0.00
	Centro-oeste	1656	1721	1739	-1.20e-5	3.21e-5	2.12e-4
Variância	Norte	2.92e+8	2.91e+8	2.89e+8	0.00961	0.00135	0.0120
	Nordeste	1.88e+6	1.87e+6	1.84e+6	0.0144	0.00955	0.0218
	Sudeste	564141	563631	563618	8.81e-4	1.20e-4	5.63e-4
	Sul	445813	444852	443885	8.25e-4	3.63e-4	9.90e-4
	Centro-oeste	2.78e+7	2.74e+7	2.71e+7	0.0184	0.00180	0.0199
Mínimo	Norte	103	103	103	-0.608	-0.376	-0.608
	Nordeste	11.1	17.0	18.6	-0.483	-0.536	-0.531
	Sudeste	2.86	3.56	3.56	-0.243	-0.348	-0.243
	Sul	27.5	27.7	27.7	-0.271	-0.287	-0.271
	Centro-oeste	56.7	57.0	55.6	-0.611	-0.309	-0.613
Máximo	Norte	159684	159534	159533	1.31	0.178	1.31
	Nordeste	16185	16304	15634	2.58	1.72	2.58
	Sudeste	10717	10727	10727	0.785	0.0948	0.289
	Sul	7804	7804	7800	0.544	0.147	0.543
	Centro-oeste	64961	64963	64432	2.61	0.469	2.59

Apêndice 3. Estatística descritiva de variáveis de população por Macrorregiões

Estatística Descritiva								
	Macrorregião	POP_03	POP_12	POP_23	PROP_VAR_POP_2003_2012	PROP_VAR_POP_2012_2023	PROP_VAR_POP_2003_2023	
N	Norte	449	450	450	449	450	449	
	Nordeste	1792	1794	1794	1792	1794	1792	
	Sudeste	1668	1668	1668	1668	1668	1668	
	Sul	1188	1191	1191	1188	1191	1188	
	Centro-oeste	463	467	467	463	467	463	
Mediana	Norte	12543	15332	15720	0.151	0.0268	0.188	
	Nordeste	13319	13947	13802	0.0688	-0.00493	0.0560	
	Sudeste	10089	10647	10884	0.0519	0.0148	0.0685	
	Sul	6953	7074	7184	0.0153	0.0136	0.0267	
	Centro-oeste	8093	8615	9303	0.0848	0.0428	0.128	
Variância	Norte	1.06e+10	1.43e+10	1.60e+10	0.0800	0.0350	0.205	
	Nordeste	1.05e+10	1.25e+10	1.16e+10	0.0231	0.0121	0.0492	
	Sudeste	9.93e+10	1.13e+11	1.13e+11	0.0197	0.0119	0.0516	
	Sul	5.72e+9	6.43e+9	6.79e+9	0.0149	0.0202	0.0693	
	Centro-oeste	1.55e+10	2.19e+10	2.55e+10	0.0548	0.0362	0.174	
Mínimo	Norte	992	1049	1164	-0.496	-0.459	-0.493	
	Nordeste	1200	1236	1318	-0.589	-0.467	-0.641	
	Sudeste	809	807	833	-0.295	-0.319	-0.446	
	Sul	1133	1232	1135	-0.432	-0.237	-0.477	
	Centro-oeste	903	1039	924	-0.353	-0.308	-0.337	
Máximo	Norte	1.53e+6	1861838	2063689	1.72	1.65	5.34	
	Nordeste	2.56e+6	2710968	2428708	2.27	1.43	4.31	
	Sudeste	1.07e+7	11376685	11451999	2.03	0.809	2.72	
	Sul	1.67e+6	1776761	1773718	0.804	0.964	1.98	
	Centro-oeste	2.19e+6	2648532	2817381	1.42	1.67	2.61	

Apêndice 4. Estatística descritiva de variáveis de população por Unidades da Federação

Estatística Descritiva								
	UF	POP_03	POP_12	POP_23	PROP_VAR_POP_2003_2012	PROP_VAR_POP_2012_2023	PROP_VAR_POP_2003_2023	
N	Rondônia	52	52	52	52	52	52	
	Acre	22	22	22	22	22	22	
	Amazonas	62	62	62	62	62	62	
	Roraima	15	15	15	15	15	15	
	Pará	143	144	144	143	144	143	
	Amapá	16	16	16	16	16	16	
	Tocantins	139	139	139	139	139	139	
	Maranhão	217	217	217	217	217	217	
	Piauí	222	224	224	222	224	222	
	Ceará	184	184	184	184	184	184	
	Rio Grande do Norte	167	167	167	167	167	167	
	Paraíba	223	223	223	223	223	223	
	Pernambuco	185	185	185	185	185	185	
	Alagoas	102	102	102	102	102	102	
	Sergipe	75	75	75	75	75	75	
	Bahia	417	417	417	417	417	417	
	Minas Gerais	853	853	853	853	853	853	
	Espírito Santo	78	78	78	78	78	78	
	Rio de Janeiro	92	92	92	92	92	92	
	São Paulo	645	645	645	645	645	645	
	Paraná	399	399	399	399	399	399	
	Santa Catarina	293	295	295	293	295	293	
	Rio Grande do Sul	496	497	497	496	497	496	
	Mato Grosso do Sul	77	79	79	77	79	77	
	Mato Grosso	139	141	141	139	141	139	
	Goiás	246	246	246	246	246	246	
	Distrito Federal	1	1	1	1	1	1	

Mediana	Rondônia	14423	14334	12344	-0.0533	-0.104	-0.144	
	Acre	12107	15607	16893	0.318	0.120	0.604	
	Amazonas	19509	23329	23802	0.175	0.103	0.279	
	Roraima	7592	10953	13986	0.344	0.270	0.844	
	Pará	24370	28394	29949	0.183	0.0503	0.208	
	Amapá	7567	12404	12069	0.327	0.0295	0.432	
	Tocantins	4468	4691	4653	0.0977	-0.0181	0.0607	
	Maranhão	15145	17722	17220	0.120	-0.0186	0.101	
	Piauí	5574	6072	5876	0.0631	9.82e-4	0.0558	
	Ceará	19337	20749	20914	0.0798	0.0106	0.0760	
	Rio Grande do Norte	7406	7805	7834	0.0713	-0.00120	0.0689	
	Paraíba	6883	7163	7066	0.0672	-0.00243	0.0688	
	Pernambuco	20488	22035	21427	0.0802	-0.00476	0.0771	
	Alagoas	15959	16983	15391	0.0547	-0.0444	-0.0108	
	Sergipe	12495	13936	13616	0.0784	-4.78e-4	0.0781	
	Bahia	16951	16672	16354	0.0329	-0.0133	0.00630	
	Minas Gerais	7672	7994	8048	0.0345	0.00268	0.0351	
	Espírito Santo	16847	18070	18897	0.0552	0.0362	0.0920	
	Rio de Janeiro	27940	35268	37767	0.0851	0.00552	0.0850	
	São Paulo	12009	12848	13163	0.0700	0.0314	0.108	
	Paraná	8995	9060	9670	0.0277	0.0176	0.0449	
	Santa Catarina	7002	7566	8319	0.0511	0.0668	0.114	
	Rio Grande do Sul	5654	5625	5378	-0.0111	-0.0225	-0.0412	
	Mato Grosso do Sul	13180	14287	13808	0.134	0.0367	0.192	
	Mato Grosso	8588	10414	10332	0.114	0.0473	0.145	
	Goiás	5996	7072	7293	0.0613	0.0383	0.103	
	Distrito Federal	2.19e+6	2648532	2817381	0.209	0.0638	0.287	
	Variância	Rondônia	2.58e+9	3.96e+9	4.38e+9	0.0712	0.0134	0.0932
		Acre	3.28e+9	5.18e+9	5.68e+9	0.0713	0.0197	0.146
		Amazonas	3.68e+10	5.46e+10	6.72e+10	0.0787	0.0282	0.0973
		Roraima	3.00e+9	5.43e+9	1.06e+10	0.0649	0.0367	0.223
		Pará	1.42e+10	1.60e+10	1.46e+10	0.104	0.0513	0.340
Amapá		6.24e+9	1.04e+10	1.18e+10	0.0982	0.0170	0.159	
Tocantins		3.59e+8	6.40e+8	9.27e+8	0.0287	0.0141	0.0540	
Maranhão		4.42e+9	5.62e+9	5.84e+9	0.0431	0.0168	0.0593	
Piauí		2.65e+9	3.20e+9	3.50e+9	0.0119	0.00511	0.0211	
Ceará		2.81e+10	3.47e+10	3.30e+10	0.0116	0.0149	0.0402	
Rio Grande do Norte		3.71e+9	4.67e+9	4.20e+9	0.0140	0.0207	0.0548	
Paraíba		2.47e+9	3.26e+9	4.02e+9	0.00988	0.00595	0.0214	
Pernambuco		1.49e+10	1.71e+10	1.65e+10	0.0147	0.0105	0.0356	
Alagoas		7.23e+9	9.12e+9	9.31e+9	0.0150	0.0155	0.0365	
Sergipe		3.35e+9	4.92e+9	5.33e+9	0.00987	0.00967	0.0306	
Bahia		1.67e+10	1.90e+10	1.58e+10	0.0357	0.0120	0.0816	
Minas Gerais		8.08e+9	9.00e+9	8.90e+9	0.0124	0.0115	0.0405	
Espírito Santo		5.76e+9	7.34e+9	8.89e+9	0.00835	0.00807	0.0252	
Rio de Janeiro		4.04e+11	4.62e+11	4.34e+11	0.0498	0.00899	0.129	
São Paulo		1.86e+11	2.11e+11	2.16e+11	0.0245	0.0125	0.0532	
Paraná		8.67e+9	9.98e+9	1.06e+10	0.0112	0.0156	0.0397	
Santa Catarina		2.02e+9	2.68e+9	3.97e+9	0.0228	0.0319	0.131	
Rio Grande do Sul		5.54e+9	5.82e+9	5.44e+9	0.0110	0.0115	0.0392	
Mato Grosso do Sul		6.70e+9	8.55e+9	1.07e+10	0.0311	0.0155	0.0742	
Mato Grosso		2.44e+9	3.06e+9	4.35e+9	0.0962	0.0452	0.279	
Goiás		6.56e+9	9.05e+9	1.10e+10	0.0361	0.0379	0.142	
Distrito Federal		NaN	NaN	NaN	NaN	NaN	NaN	

Amplitude	Rondônia	351390	440418	458278	1.62	0.570	1.43	
	Acre	271826	343293	358033	0.899	0.529	1.45	
	Amazonas	1.52e+6	1854390	2054831	1.49	0.816	1.59	
	Roraima	215768	289991	406171	0.935	0.713	1.49	
	Pará	1.34e+6	1407051	1299372	2.22	2.11	5.67	
	Amapá	316208	411533	439130	1.33	0.426	1.59	
	Tocantins	171184	241021	301528	0.981	0.658	1.36	
	Maranhão	919373	1035818	1033455	1.41	1.29	1.50	
	Piauí	750058	828995	864982	0.803	0.414	1.07	
	Ceará	2.25e+6	2496238	2423867	0.838	1.22	1.51	
	Rio Grande do Norte	743208	815957	749478	0.942	1.66	2.42	
	Paraíba	627638	740771	832233	0.636	0.475	0.948	
	Pernambuco	1.46e+6	1552321	1485753	0.999	0.755	1.39	
	Alagoas	847061	950536	955185	0.717	1.00	1.12	
	Sergipe	477495	585411	600587	0.544	0.768	1.30	
	Bahia	2.55e+6	2707753	2414244	2.85	1.04	4.95	
	Minas Gerais	2.30e+6	2394978	2314727	1.18	1.10	2.03	
	Espírito Santo	365686	420477	515570	0.384	0.443	0.593	
	Rio de Janeiro	5.97e+6	6384963	6205808	1.84	0.600	2.82	
	São Paulo	1.07e+7	11375878	11451092	2.28	1.05	2.21	
	Paraná	1.67e+6	1775369	1772395	1.17	0.985	1.47	
	Santa Catarina	459967	524907	614666	1.04	1.13	2.22	
	Rio Grande do Sul	1.39e+6	1415482	1331698	0.698	0.945	1.31	
	Mato Grosso do Sul	703049	802452	894561	0.922	0.732	1.49	
	Mato Grosso	507005	560271	649867	1.71	1.23	2.95	
	Goiás	1.15e+6	1332728	1436442	1.67	1.86	2.71	
	Distrito Federal	0.00	0	0	0.00	0.00	0.00	
	Mínimo	Rondônia	2571	2283	2156	-0.364	-0.366	-0.493
		Acre	2729	5061	6723	-0.0277	-0.0584	0.0132
		Amazonas	6729	7448	8858	-0.358	-0.297	-0.333
Roraima		5259	6968	7315	-0.187	0.0498	0.0564	
Pará		3361	3379	4031	-0.496	-0.459	-0.325	
Amapá		2553	4021	3803	0.130	-0.157	0.0928	
Tocantins		992	1049	1164	-0.227	-0.245	-0.288	
Maranhão		4153	3792	4320	-0.448	-0.434	-0.231	
Piauí		1406	1236	1318	-0.341	-0.166	-0.322	
Ceará		4651	3956	4841	-0.323	-0.467	-0.385	
Rio Grande do Norte		1586	1633	1822	-0.450	-0.224	-0.484	
Paraíba		1200	1707	1699	-0.170	-0.229	-0.301	
Pernambuco		2163	2718	3167	-0.426	-0.406	-0.479	
Alagoas		2673	2857	2731	-0.307	-0.386	-0.338	
Sergipe		2272	2290	2170	-0.151	-0.175	-0.159	
Bahia		3036	3215	3434	-0.589	-0.413	-0.641	
Minas Gerais		879	807	833	-0.295	-0.319	-0.446	
Espírito Santo		5041	4471	5083	-0.113	-0.130	-0.113	
Rio de Janeiro		4685	5327	5415	-0.0773	-0.140	-0.0958	
São Paulo		809	807	907	-0.249	-0.241	-0.311	
Paraná		1379	1392	1323	-0.432	-0.223	-0.477	
Santa Catarina		1609	1431	1651	-0.239	-0.164	-0.246	
Rio Grande do Sul		1133	1232	1135	-0.261	-0.237	-0.357	
Mato Grosso do Sul		2926	2945	3539	-0.187	-0.180	-0.193	
Mato Grosso		1151	1058	1010	-0.287	-0.308	-0.337	
Goiás		903	1039	924	-0.353	-0.186	-0.306	
Distrito Federal		2.19e+6	2648532	2817381	0.209	0.0638	0.287	

Máximo	Rondônia	353961	442701	460434	1.25	0.204	0.940
	Acre	274555	348354	364756	0.871	0.471	1.46
	Amazonas	1.53e+6	1861838	2063689	1.13	0.519	1.26
	Roraima	221027	296959	413486	0.748	0.763	1.54
	Pará	1.34e+6	1410430	1303403	1.72	1.65	5.34
	Amapá	318761	415554	442933	1.46	0.269	1.68
	Tocantins	172176	242070	302692	0.754	0.413	1.07
	Maranhão	923526	1039610	1037775	0.967	0.858	1.27
	Piauí	751464	830231	866300	0.462	0.247	0.752
	Ceará	2.26e+6	2500194	2428708	0.515	0.756	1.12
	Rio Grande do Norte	744794	817590	751300	0.492	1.43	1.94
	Paraíba	628838	742478	833932	0.466	0.246	0.647
	Pernambuco	1.46e+6	1555039	1488920	0.573	0.349	0.913
	Alagoas	849734	953393	957916	0.410	0.616	0.786
	Sergipe	479767	587701	602757	0.393	0.593	1.14
	Bahia	2.56e+6	2710968	2417678	2.27	0.626	4.31
	Minas Gerais	2.31e+6	2395785	2315560	0.883	0.782	1.58
	Espírito Santo	370727	424948	520653	0.271	0.313	0.480
	Rio de Janeiro	5.97e+6	6390290	6211223	1.76	0.460	2.72
	São Paulo	1.07e+7	11376685	11451999	2.03	0.809	1.90
	Paraná	1.67e+6	1776761	1773718	0.733	0.762	0.997
	Santa Catarina	461576	526338	616317	0.804	0.964	1.98
	Rio Grande do Sul	1.39e+6	1416714	1332833	0.437	0.708	0.955
	Mato Grosso do Sul	705975	805397	898100	0.735	0.552	1.29
	Mato Grosso	508156	561329	650877	1.42	0.925	2.61
	Goiás	1.15e+6	1333767	1437366	1.32	1.67	2.40
	Distrito Federal	2.19e+6	2648532	2817381	0.209	0.0638	0.287