



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA
PROGRAMA DE PÓS-GRADUAÇÃO EM MODELAGEM EM
CIÊNCIAS DA TERRA E DO AMBIENTE

SAMUEL CONCEIÇÃO DE MATOS

DETECÇÃO DE HOTSPOTS DE DESMATAMENTO NA CIDADE DE
CANAVIEIRAS/BA, POR MEIO DA MODELAGEM RISK TERRAIN
MODELLING (RTM), COMO UMA ESTRÁTEGIA PARA A IMPLANTAÇÃO
DO POLICIAMENTO PREDITIVO

Feira de Santana/BA

2024

SAMUEL CONCEIÇÃO DE MATOS

**DETECÇÃO DE HOTSPOTS DE DESMATAMENTO NA CIDADE DE
CANAVIEIRAS/BA, POR MEIO DA MODELAGEM RISK TERRAIN
MODELLING (RTM), COMO UMA ESTRÁTEGIA PARA A IMPLANTAÇÃO
DO POLICIAMENTO PREDITIVO**

Dissertação apresentada como requisito obrigatório para a obtenção do título de Mestre em Ciências Ambientais do Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente da Universidade Estadual de Feira de Santana.

Eixo temático: Segurança Pública e Meio Ambiente

Orientador: Prof. Dr. Marcos Rosa

Feira de Santana/BA

2024

Ficha Catalográfica - Biblioteca Central Julieta Carteado - UEFS

M382 Matos, Samuel Conceição de

Detecção de hotspots de desmatamento na cidade de Canavieiras/BA, por meio da modelagem Risk Terrain Modelling (RTM), como uma estratégia para a implantação do policiamento preditivo / Samuel Conceição de Matos. – 2024.

96 f. : il.

Orientador: Marcos Reis Rosa

Dissertação (mestrado) - Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente, Departamento de Ciências Exatas, Universidade Estadual de Feira de Santana, Feira de Santana, 2024.

1. Hotspots. 2. Desmatamento – Canavieiras, Bahia. 3. Risk Terrain Modelling (RTM). 4. Mata atlântica. 5. Criminologia ambiental. I. Título. II. Rosa, Marcos Reis, orient. III. Departamento de Ciências Exatas. IV. Programa de Pós-graduação em Modelagem em Ciências da Terra e do Ambiente. V. Universidade Estadual de Feira de Santana.

CDU 504:528.8(814.22)

Samuel Conceição de Matos

“DETECÇÃO DE HOTSPOTS DE DESMATAMENTO NA CIDADE DE CANAVIEIRAS/BA, POR MEIO DA MODELAGEM RISK TERRAIN MODELLING (RTM), COMO UMA ESTRATÉGIA PARA A IMPLANTAÇÃO DO POLICIAMENTO PREDITIVO”

Dissertação apresentada ao Programa de Pós-Graduação em Modelagem em Ciências da Terra e do Ambiente da Universidade Estadual de Feira de Santana.

Orientador: Prof. Dr. Marcos Reis Rosa.

Linha de Pesquisa: Estudos Ambientais e Geotecnologias.

Data de aprovação: 30 de julho de 2024.

BANCA EXAMINADORA:

Documento assinado digitalmente
gov.br MARCOS REIS ROSA
Data: 31/07/2024 16:20:25-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Marcos Reis Rosa
Universidade Estadual de Feira de Santana - UEFS

Documento assinado digitalmente
gov.br RODRIGO NOGUEIRA DE VASCONCELOS
Data: 31/07/2024 14:32:19-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Rodrigo N. Vasconcelos
Universidade Estadual de Feira de Santana - UEFS

Documento assinado digitalmente
gov.br ANTONIO HOT PEREIRA DE FARIA
Data: 01/08/2024 16:52:31-0300
Verifique em <https://validar.itl.gov.br>

Prof. Dr. Antônio Hot Pereira de Faria
Centro de Pesquisa e Pós-Graduação da Academia de Polícia Militar de Minas Gerais

SUMÁRIO

1	INTRODUÇÃO.....	14
2	REFERENCIAL TEÓRICO	17
2.1	POLICIAMENTO OSTENSIVO.....	17
2.2	POLICIAMENTO PREDITIVO	18
2.3	CRIMINOLOGIA AMBIENTAL.....	19
2.4	MAPEAMENTO DE <i>HOTSPOTS</i> CRIMINAIS.....	22
2.5	MÉTRICAS DE AVALIAÇÃO DE MAPEAMENTO DE <i>HOTSPOTS</i> CRIMINAIS	24
2.6	<i>RISK TERRAIN MODELLING</i> (RTM).....	27
2.7	DESMATAMENTO.....	33
2.8	VETORES DE DESMATAMENTO	36
2.9	DESMATAMENTO NO BRASIL	42
2.10	DESMATAMENTO NO BIOMA MATA ATLÂNTICA	43
3	QUESTÃO NORTEADORA.....	46
4	OBJETIVOS	47
4.1	OBJETIVO GERAL.....	47
4.2	OBJETIVOS ESPECÍFICOS	47
5	METODOLOGIA.....	47
5.1	CARACTERIZAÇÃO DA ÁREA DE ESTUDO	48
5.2	DETERMINAÇÃO DOS FATORES DE RISCO DE DESMATAMENTO.....	51
5.1	APLICAÇÃO DA MODELAGEM RTM.....	52
5.1.1	PRÉ-PROCESSAMENTO	53
5.1.2	PROCESSAMENTO DOS DADOS.....	57
6	RESULTADOS.....	59
6.1	CARACTERIZAÇÃO DO USO E COBERTURA DO SOLO EM CANAVIEIRAS.....	59
6.2	CARACTERIZAÇÃO DO DESMATAMENTO DE FLORESTAS EM CANAVIEIRAS.....	63
6.3	RESULTADOS DECORRENTES DA ANÁLISE DE REGRESSÃO ESTATÍSTICA BINOMIAL.....	66
6.4	MAPAS DE <i>HOTSPOTS</i> DE DESMATAMENTO GERADOS PELA MODELAGEM RTM PARA OS ANOS DE 2019 A 2022	70
6.5	RESULTADOS DA AVALIAÇÃO DA CAPACIDADE PREDITIVA DA MODELAGEM RTM NA IDENTIFICAÇÃO DE <i>HOTSPOTS</i> DE DESMATAMENTO.....	73
6.6	RESULTADOS DA MODELAGEM RTM PARA A ORIENTAÇÃO E PLANEJAMENTO DAS ATIVIDADES POLICIAIS.....	75
7	DISCUSSÃO.....	76
8	CONCLUSÃO.....	80

REFERÊNCIAS	83
APÊNDICE I	90
APÊNDICE II	91
APÊNDICE III	94
APÊNDICE IV	95
APÊNDICE V	96
APÊNDICE VI	98

FIGURAS

Figura 1. Ilustração da métrica DVI.....	26
Figura 2. Representação sucinta do processo de modelagem RTM	28
Figura 3. Temas de pesquisas que incorporaram a modelagem RTM na sua metodologia para prever ocorrências criminais.....	32
Figura 4. Sistematização das principais causas de desmatamento em florestas tropicais proposta por Geist e Lambin (2001)	37
Figura 5. Localização geográfica e abrangência territorial do bioma Mata Atlântica.....	44
Figura 6. Mapa de localização do município de Canavieiras/BA	49
Figura 7. Classificação em categorias de Nível 1 dos tipos de uso e cobertura do solo identificados em Canavieiras/BA em 2022.....	50
Figura 8. Processo de uso e ocupação do solo no município de Canavieiras/BA de 1985 a 2022.....	51
Figura 9. Fluxograma adotado para a modelagem RTM.....	53
Figura 10. Divisão do território de Canavieiras/BA em grids hexagonais.....	54
Figura 11. Delimitação da área de estudo e geração de camadas shapefile dos fatores de risco	55
Figura 12. Processo de integração das camadas dos fatores de risco ao shapefile da área de estudo	56
Figura 13. Hotspots de desmatamento em Canavieiras/BA em 2019.....	70
Figura 14. Hotspots de desmatamento em Canavieiras/BA em 2020.....	71
Figura 15. Hotspots de desmatamento em Canavieiras/BA em 2021.....	72
Figura 16. Hotspots de desmatamento em Canavieiras/BA em 2022.....	72
Figura 17. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2019	94
Figura 18. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2020	94
Figura 19. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2021	94
Figura 20. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2022	94
Figura 21. Distribuição espacial dos alertas de desmatamento ocorridos em Canavieiras entre 2019 e 2022 utilizando-se o EDK	95

Figura 22. Classificação das células do grid conforme o grau de risco para o ano de 2019 no município de Canavieira/BA.....	96
Figura 23. Classificação das células do grid conforme o grau de risco para o ano de 2020 no município de Canavieira/BA.....	96
Figura 24. Classificação das células do grid conforme o grau de risco para o ano de 2021 no município de Canavieira/BA.....	97
Figura 25. Classificação das células do grid conforme o grau de risco para o ano de 2022 no município de Canavieira/BA.....	97

TABELAS

Tabela 1. Inclinação do território do município de Canavieiras/BA, segundo classificação da EMBRAPA (1999)	49
Tabela 2. Relação da área ocupada por cada categoria de uso e cobertura da terra no município de Canavieiras/BA em 2022	60
Tabela 3. Área, em km ² , ocupada por florestas, pela agropecuária e zona urbana em Canavieiras/BA entre 1985 e 2022	61
Tabela 4. Densidade de alertas de desmatamento por área de cobertura florestal em Canavieiras durante o período de 2019 e 2022	63
Tabela 5. Área dos alertas de desmatamento, segundo a declividade local, no município de Canavieiras/BA	65
Tabela 6. Área desmatada, em hectares, por classe de tamanho, registrada em Canavieiras/BA entre 2019 e 2022	65
Tabela 7. Fatores de risco de desmatamento considerados estatisticamente significantes no município de Canavieiras/BA e seus coeficientes e intercepto para o período entre 2019 e 2022	66
Tabela 8. Taxa mínima, máxima, média e desvio padrão do conjunto de dados de VRL de 2019 a 2022 encontrados em Canavieiras/BA	68
Tabela 9. Comparação entre a taxa média de risco de desmatamento e a área de cobertura florestal em Canavieiras entre 2020 e 2022	69
Tabela 10. Porcentagem de células classificadas no grid como baixo, médio, alto e altíssimo risco entre 2019 e 2022	69
Tabela 11. Taxa de acerto na previsão de alertas de desmatamento em Canavieiras/BA com um intervalo de um ano entre as faixas de previsão	73
Tabela 12. Resultados do Índice de Acurácia Preditiva (PAI) para a previsão de alertas de desmatamento em Canavieiras/BA entre 2019 e 2022	74
Tabela 13. Resultados do RRI para avaliar a precisão do modelo RTM na previsão de áreas suscetíveis ao desmatamento em Canavieiras/BA durante o período de 2019 a 2022.	74
Tabela 14. Resultados da APR para avaliar o grau de compactação dos hotspots de desmatamento em Canavieiras/BA durante o período de 2019 a 2022	75
Tabela 15. Avaliação da estabilidade dos hotspots de desmatamento em Canavieiras/BA, segundo o DVI, durante o período de 2019 a 2022.	76

QUADROS

Quadro 1. Explicação sumária das teorias integrantes da criminologia ambiental	21
Quadro 2. Síntese dos métodos de regressão utilizados na modelagem RTM	30
Quadro 3. Nível de escala e exemplos de fatores (atividades específicas) relacionados com as causas de desmatamento em florestas tropicais	38
Quadro 4. Fatores associados com o aumento ou com a redução da taxa do desmatamento em florestas tropicais	40
Quadro 5. Fatores de risco que influenciam no desmatamento de florestas tropicais segundo Geist e Lambin (2001).....	52
Quadro 6. Descrição dos pacotes e bibliotecas utilizadas na análise dos dados neste estudo	58
Quadro 7. Classificação dos valores de risco local (VRL) segundo Limeira (2022).....	59
Quadro 8. Dados utilizados na construção do modelo RTM e suas fontes.....	90
Quadro 9. Síntese das técnicas de mapeamento hotspots mais comuns, segundo Chainey et al. (2008).....	91

GRÁFICOS

Gráfico 1. Relação da área ocupada por floresta, agropecuária e zona urbana no município de Canavieiras/BA entre 1985 e 2022	62
Gráfico 2. Quantidade de alertas de desmatamentos registrados em Canavieiras/BA entre 2019 e 2022.....	63
Gráfico 3. Área de floresta desmatada em Canavieiras, em hectares, entre 2019 e 2022	64

RESUMO

Este estudo investiga a detecção de *hotspots* de desmatamento no município de Canavieiras, Bahia, por meio da modelagem *Risk Terrain Modelling* (RTM). O referencial teórico examina conceitos como policiamento ostensivo, policiamento preditivo, criminologia ambiental e técnicas de mapeamento de *hotspots* criminais. Nele, destaca-se a aplicação do RTM para identificar *hotspots* de desmatamento, adaptando princípios da criminologia ambiental ao contexto da degradação florestal, com o intuito de otimizar operações de monitoramento e fiscalização, contribuindo para a conservação ambiental. Além disso, o estudo buscou identificar os fatores de risco que contribuem para o desmatamento. A metodologia adotada neste estudo consistiu na divisão da área de estudo em *grids* e na utilização de dados geoespaciais relacionados aos fatores de risco de desmatamento, selecionados com base em literatura especializada. Esses fatores incluíram declividade, áreas de pastagem, rodovias, entre outros. Os dados foram empregados como variáveis de entrada para o RTM. Para identificar os fatores de risco estatisticamente significativos associados ao desmatamento entre 2019 e 2022, foi realizada uma análise de regressão binomial. Os resultados revelaram a recorrência de fatores de risco de desmatamento, como áreas com Cadastro Ambiental Rural (CAR), pastagens e terrenos com declividade suave. Observou-se que mais da metade dos alertas de desmatamento ocorreu em áreas planas, e que mais de 94% da área desmatada estava concentrada em terrenos de pequena extensão, apresentando uma assimetria positiva nos dados de alertas, refletindo um padrão frequentemente observado em ocorrências criminais. No que diz respeito à classificação das células do grid, as áreas designadas como de alto ou altíssimo risco representaram uma porcentagem menor em comparação às classificadas como risco médio ou baixo, o que corrobora achados de literaturas sobre ocorrências criminais. Além disso, identificou-se que os *hotspots* de desmatamento estão predominantemente localizados nas bordas e clareiras dos fragmentos florestais. Isso evidencia que os *hotspots* de desmatamento não ocorrem de maneira aleatória ou uniforme, mas seguem padrões previsíveis, semelhantes aos crimes comuns. Adicionalmente, a eficácia do modelo RTM foi avaliada por meio de métricas de avaliação preditiva. Os principais resultados indicaram uma taxa de acerto de 67% na previsão dos alertas de desmatamento, com maior precisão nos anos de 2020 e 2021. O Índice de Taxa de Recaptura (RRI) demonstrou que, apesar da precisão geral ser moderada, o ano de 2020 apresentou um desempenho superior, com um RRI acima de 1. Observou-se que a modelagem RTM demonstrou ser robusta e eficaz na previsão de *hotspots* de desmatamento, indicando que o policiamento preditivo pode ser adaptado para a conservação ambiental. Este estudo apresenta uma ferramenta promissora para a alocação mais eficiente de recursos de fiscalização, o que pode contribuir significativamente para a proteção dos remanescentes florestais em Canavieiras.

Palavras-chave: Desmatamento, Mata Atlântica, *Hotspots*, *Risk Terrain Modelling*, Policiamento Preditivo

ABSTRACT

This study investigates the detection of deforestation hotspots in the municipality of Canavieiras, Bahia, using Risk Terrain Modeling (RTM). The theoretical framework examines concepts such as overt policing, predictive policing, environmental criminology and criminal hotspot mapping techniques. It highlights the application of RTM to identify deforestation hotspots, adapting principles of environmental criminology to the context of forest degradation, in order to optimize monitoring and enforcement operations, contributing to environmental conservation. The study also sought to identify the risk factors that contribute to deforestation. The methodology adopted in this study consisted of dividing the study area into grids and using geospatial data related to deforestation risk factors, selected on the basis of specialized literature. These factors included slope, pasture areas, roads, among others. The data was used as input variables for the RTM. To identify the statistically significant risk factors associated with deforestation between 2019 and 2022, a binomial regression analysis was carried out. The results revealed the recurrence of deforestation risk factors, such as areas with Rural Environmental Registration (CAR), pastures and land with gentle slopes. It was observed that more than half of the deforestation alerts occurred in flat areas, and that more than 94% of the deforested area was concentrated on small plots of land, showing a positive asymmetry in the alert data, reflecting a pattern often observed in criminal occurrences. With regard to the classification of grid cells, the areas designated as high or very high risk represented a lower percentage than those classified as medium or low risk, which corroborates findings in the literature on crime. In addition, it was found that deforestation hotspots are predominantly located on the edges and clearings of forest fragments. This shows that deforestation hotspots do not occur randomly or uniformly, but follow predictable patterns, similar to common crimes. In addition, the effectiveness of the RTM model was assessed using predictive evaluation metrics. The main results indicated an accuracy rate of 67% in predicting deforestation alerts, with greater accuracy in 2020 and 2021. The Recapture Rate Index (RRI) showed that, although the overall accuracy was moderate, the year 2020 showed superior performance, with an RRI above 1. It was observed that RTM modeling proved to be robust and effective in predicting deforestation hotspots, indicating that predictive policing can be adapted for environmental conservation. This study presents a promising tool for the more efficient allocation of enforcement resources, which can contribute significantly to the protection of forest remnants in Canavieiras

Key words: Deforestation, Atlantic Forest, Hotspots, Risk Terrain Modelling, Predictive Policing

1. INTRODUÇÃO

A Constituição da República Federativa do Brasil de 1988 atribuiu às polícias militares do país o dever de preservar a ordem pública e a segurança das pessoas e do patrimônio através do policiamento ostensivo, atividade realizada mediante a adoção de medidas preventivas e repressivas.

Ao examinar a atuação das forças policiais no Brasil, Beato Filho (2000) identificou deficiências nessas organizações para lidar com o aumento da criminalidade, ressaltando a importância da implementação de inovações tecnológicas para substituir o modelo tradicional de policiamento, que, conforme apontado por Silva (2017), é reativo e baseado na distribuição aleatória de efetivos.

Nesse contexto, vários modelos de gestão policial foram desenvolvidos com o objetivo comum de aprimorar as decisões dos gestores policiais, substituindo abordagens subjetivas por decisões embasadas em informações pertinentes que contribuam para uma compreensão mais eficaz da atividade criminosa (Silva, 2017).

Dentro dessa perspectiva, surgiu o policiamento preditivo, um modelo de gestão policial que utiliza técnicas avançadas para a previsão de crimes. Segundo Perry *et al* (2013), o policiamento preditivo parte do pressuposto da tendência em se repetir ações delituosas com base em experiências bem-sucedidas anteriormente.

Cabe destacar que o crime é um fenômeno locacional, apresentando concentração em determinados lugares, enquanto em outros está ausente, sendo a criminologia ambiental a disciplina responsável pelo estudo deste fenômeno. Seu objetivo principal é compreender como características ambientais moldam eventos criminosos para a alocação de recursos e esforços na investigação, controle e prevenção da criminalidade (Guillén, 2013).

De acordo com Andresen (2014), a criminologia ambiental destaca a existência de *hotspots* criminais, áreas com alta concentração de atividade criminosa. Segundo Chainey *et al.* (2008), o mapeamento de *hotspots* é uma ferramenta fundamental na previsão de crimes, destacando o Mapeamento de Pontos e a Estimativa de Densidade Kernel (EDK) como as técnicas de mapeamento de *hotspots* mais comuns.

Apesar de úteis na previsão de crimes, essas técnicas tendem a supor que o crime permanecerá estático, desconsiderando sua natureza dinâmica ao longo do tempo. Ao se basear exclusivamente em registros passados de crimes, elas negligenciam o contexto do ambiente construído ao tentar prever ocorrências criminas futuras (Drawve, 2016). Tais

limitações podem ser superadas com a adoção da modelagem *Risk Terrain Modelling* (RTM).

A modelagem RTM incorpora em sua análise as características ambientais que se acredita contribuir para a formação de áreas de risco, indo além dos registros históricos de crimes (objeto de estudo desta pesquisa, visto que o RTM pode ser empregado para previsão de riscos diversos). A análise do crime deixa de ser estática e passa a ser dinâmica, pois, caso haja uma mudança no padrão de crime, o RTM poderá prever onde ele ocorrerá, inovando ao considerar características ambientais como elementos de risco para o crime (Drawve, 2016).

Marchment e Gill (2021) conduziram uma meta-análise que examinou diversos artigos que utilizaram a modelagem RTM para prever uma ampla gama de crimes, como roubo e furto residencial, homicídios, entre outros. Contudo, entre os estudos examinados, não foi identificado nenhum artigo que utilizasse a modelagem RTM para prever crimes ambientais, especialmente o desmatamento ilegal.

Sabe-se que o desmatamento causa uma série de impactos negativos significativos no meio ambiente, incluindo a redução da biodiversidade, propagação de doenças, mudanças climáticas e a diminuição da fertilidade do solo (Miller; Spoolman, 2015). Além disso, esses efeitos resultam na redução de serviços ecossistêmicos cruciais para a sobrevivência humana e para economia. Portanto, é crucial adotar medidas imediatas para mitigar esses impactos, visando preservar a biodiversidade, manter os serviços ecossistêmicos essenciais a vida e garantir um desenvolvimento sustentável.

Assim, inspirado nos estudos de Geist e Lambin (2001) e nos fundamentos da criminologia ambiental, esta pesquisa empregou a modelagem RTM para identificar *hotspots* de desmatamento ilegal no município de Canavieiras/Bahia, região situada no bioma Mata Atlântica a apresentar o maior número de alertas de desmatamento, de acordo com o MapBiomas Alerta (2022).

Embora a abordagem analítica do RTM seja amplamente utilizada para prever crimes em ambientes urbanos, destaca-se que ela possui potencial para prever crimes em áreas rurais, especialmente aqueles relacionados a crimes ambientais, como o desmatamento ilegal. Acredita-se que esta pesquisa seja pioneira ao integrar a praticidade da criminologia ambiental com as ciências ambientais, mediante a aplicação da modelagem RTM para prever áreas com potencial de desmatamento, preenchendo uma lacuna na literatura acadêmica. Este estudo não apenas enriquece o corpo teórico-acadêmico das ciências

criminais e ambientais com abordagens inovadoras, mas também aprimora as práticas policiais, resultando em ações mais eficientes e eficazes.

Isso contribui para a preservação da ordem pública, uma vez que a degradação ambiental compromete a segurança e o bem-estar da sociedade. Além disso, deseja-se que este trabalho sirva de inspiração para a elaboração de planos estratégicos e operacionais de combate ao desmatamento ilegal, auxiliando na tomada de decisão e na alocação eficiente de recursos humanos e financeiros.

Destaca-se que este estudo está alinhado com os Objetivos de Desenvolvimento Sustentável (ODS) da ONU, em particular com o ODS nº 13 (ação contra a mudança global do clima), o ODS nº 15 (vida terrestre) e o ODS nº 16 (paz, justiça e instituições eficazes), ao promover práticas de previsão e intervenção que visam mitigar o desmatamento e preservar ecossistemas terrestres. Essa abordagem não apenas contribui para a sustentabilidade ambiental, mas também fortalece a capacidade das instituições policiais em proteger a ordem pública diante dos impactos adversos da degradação ambiental.

Esta pesquisa está estruturada da seguinte maneira: primeiro, apresenta-se o embasamento teórico, explorando temas relacionados ao assunto em questão; em seguida, descreve-se a metodologia adotada, incluindo detalhes sobre a coleta e análise de dados; por fim, são apresentados os resultados obtidos com a aplicação da modelagem RTM, seguidos das discussões e conclusões alcançadas.

2. REFERENCIAL TEÓRICO

2.1. POLICIAMENTO OSTENSIVO

O art. 144 da Constituição Federal (CF) de 1988 atribuiu às policiais militares o dever de preservar a ordem pública, bem como a incolumidade das pessoas e do patrimônio por meio do policiamento ostensivo (ação de presença identificada através do fardamento, armamento e viatura). Este fato, segundo Raymundo (2023), é o foco principal da Polícia Militar: a capacidade de ser vista e percebida pela população, necessária, segundo o autor, para a manutenção da ordem pública.

O policiamento ostensivo, em síntese, engloba a implementação de medidas preventivas e repressivas. As ações preventivas derivam de práticas de antecipação a conduta criminosa, fundamentadas na presença física dos policiais militares, visando prevenir ou minimizar tais comportamentos. Por outro lado, as ações repressivas ocorrem em casos de grave perturbação da ordem pública, com o objetivo de restabelecê-la.

De acordo com Meirelles *et al* (2012) *apud* Nascimento e Nascimento (2018), as ações preventivas desempenham um papel crucial ao evitar uma série de danos à sociedade, frequentemente considerados irreversíveis. Isso abrange desde bens materiais de valor inestimável até os impactos psicológicos sofridos pelas vítimas e seus familiares.

Já as ações repressivas, situadas entre as atividades de prevenção e investigação criminal, destacam-se como as atividades mais visíveis no âmbito do policiamento ostensivo, especialmente durante a solução de conflitos delituosos. Essa medida é ocasionalmente essencial e requer uma aplicação imediata, ficando a cargo da polícia militar a decisão sobre a forma e os meios necessários a serem empregados no reestabelecimento da ordem pública (Raymundo, 2023).

Em regra, o policiamento ostensivo ocorre por meio de patrulhamento (atividades de deslocamento) e permanência (presença em locais definidos), sendo imprescindível a alocação racional dos recursos humanos e financeiros na redução da criminalidade (Limeira, 2022). Cabe salientar que a segurança pública, como aponta o artigo 144 da Constituição Federal de 1988, além de ser um direito do cidadão e dever do Estado, é responsabilidade de todos, demonstrando a importância do envolvimento de toda a sociedade no combate ao crime.

2.2. POLICIAMENTO PREDITIVO

Beato Filho (2000) identificou deficiências nas organizações policiais brasileiras diante do aumento da criminalidade, argumentando que mudanças na gestão, na tomada de decisão, no planejamento e nas estratégias policiais são necessárias para enfrentar esse desafio. Ele também ressaltou a importância de adotar inovações tecnológicas em oposição ao modelo tradicional de policiamento, que Silva (2017) caracteriza como reativo e baseado na distribuição aleatória de policiais. Esse contexto destaca a urgência de novas abordagens na gestão policial para melhorar sua eficiência.

Com base nesse contexto, foram desenvolvidos diversos modelos de gestão policial, como o Policiamento Orientado para Problemas, o Policiamento Comunitário, o Policiamento Orientado para Inteligência, entre outros. Todos esses modelos compartilham o objetivo comum de aprimorar as decisões dos gestores, substituindo abordagens arbitrárias e subjetivas por decisões embasadas em informações pertinentes que contribuam para uma compreensão mais eficaz da atividade criminosa (Silva, 2017).

Algumas forças policiais, especialmente em países desenvolvidos, têm adotado técnicas de previsão de crimes para aprimorar a gestão de suas atividades no enfrentamento ao crime (Ohyama; Amemiya, 2018). Isto, por sua vez, lhes proporcionou a identificação antecipada de alvos, possibilitando uma alocação mais eficiente de recursos humanos e financeiros limitados na resolução de delitos. O emprego desse método ficou conhecido como Policiamento Preditivo (Perry *et al*, 2013).

Uchida (2009) propôs um conceito mais abrangente de policiamento preditivo. Segundo o autor, o policiamento preditivo pode ser caracterizado como o emprego de estratégias policiais que gerem ou empreguem informações e análises avançadas para fazer previsões de crimes. Isso envolve a utilização de geotecnologias e modelos de intervenção fundamentados em evidências, visando a redução do crime e a melhoria da segurança pública (NJI, 2014). No entanto, a implementação das suas técnicas deve ser baseada em dados específicos relacionados ao objeto de estudo, permitindo assim a identificação de potenciais vítimas ou áreas com maior probabilidade de ocorrências criminosas (Perry *et al*, 2013; Silva, 2017).

Perry *et al*. (2013) sustentam que o crime é previsível uma vez que os criminosos costumam agir dentro de sua zona de conforto em termos de área, alvo e risco de serem capturados. Conforme esses autores, os criminosos têm a tendência de cometer delitos que foram anteriormente bem-sucedidos, frequentemente nas proximidades do mesmo

horário e local. Embora essa tendência não seja universal, sua ocorrência frequente permite que métodos como o policiamento preditivo funcionem de maneira satisfatória. A lógica subjacente a essa abordagem é a habilidade de identificar padrões e implementar intervenções táticas para prevenir a ocorrência de crimes (Perry *et al.*, 2013), métodos associados as análises criminal e prescritiva.

Percebe-se que análise criminal é a base do policiamento preditivo. Ela envolve a coleta e a análise de dados relacionados a crimes passados para identificar tendências e padrões. Esses dados podem incluir a localização dos crimes, horários de ocorrência, tipos de crimes, entre outros fatores contextuais que podem influenciar a atividade criminosa (Moraes, 2016). Isso fornece *insights* valiosos para as forças policiais, oferecendo a base de dados necessária para que o policiamento preditivo funcione de maneira eficaz e forneça um panorama claro sobre onde as forças de segurança devem concentrar seus esforços. Já a análise prescritiva vai além dessa abordagem.

Enquanto a análise criminal informa onde e quando os crimes podem ocorrer, a análise prescritiva, no âmbito criminal, se concentra em encontrar ações devem ser adotadas para eliminar ou reduzir riscos previstos (Brandt *et al.* 2022), potencializando o policiamento preditivo. Nesse contexto, a análise prescritiva pode recomendar o deslocamento de patrulhas, a intensificação do policiamento, a implementação de operações policiais em áreas de alto risco ou até mesmo mudanças nas políticas de segurança. De acordo com Taylor (2015), a análise prescritiva é crucial para transformar dados em ações práticas e eficazes.

Juntas, essas abordagens fornecem uma base sólida para a criação de estratégias de policiamento mais informadas e eficientes, permitindo uma resposta mais ágil e adaptativa ao crime. Isso maximiza a eficácia das forças policiais e minimiza a ocorrência de crimes, promovendo comunidades mais seguras e bem protegidas. No entanto, isso requer uma capacitação adequada e contínua das forças policiais. É necessário que elas aprendam a interpretar os dados e aplicar as recomendações das análises de forma eficaz.

2.3. CRIMINOLOGIA AMBIENTAL

É crucial destacar que o crime possui qualidades geográficas intrínsecas, ou seja, é um fenômeno locacional e, portanto, não se distribui de maneira aleatória nem uniforme no espaço (Perry *et al.* 2013), apresentando concentração em determinados lugares, enquanto em outros está ausente (Eck, 2005; Andresen, 2014), mesmo que apresente uma

diversidade considerável em tipos e naturezas (Guillén, 2013). Dessa maneira, a análise das características do ambiente onde o crime ocorre emerge como um componente essencial no combate à criminalidade (Chainey *et al.*, 2008).

Segundo Braga (2005), mais da metade de todos os crimes em uma cidade ocorre em locais específicos, associando esse padrão às características físicas e sociais da área. Conforme Eck (2005) destacou, essa compreensão já é empregada pelas organizações policiais, exercendo influência parcial nas decisões relacionadas à distribuição do policiamento. A concentração da criminalidade em locais e momentos específicos é explorada pela criminologia ambiental.

A criminologia ambiental constitui um ramo de estudo da criminologia dedicado à análise da influência do ambiente na manifestação de comportamentos criminosos. Seu propósito é compreender por que determinadas áreas exibem maior propensão à criminalidade, identificando padrões criminais e explicando-os em termos de influências ambientais. A partir dessas análises, são desenvolvidas estratégias de prevenção ao crime (Wortley; Townsley, 2017). Segundo Guillén (2013), a criminologia ambiental tem apresentado soluções práticas e eficazes na análise, intervenção e prevenção da criminalidade, diferentemente da criminologia tradicional.

Segundo Clarke e Eck (2016), as teorias da criminologia tradicional concentram-se nos fatores que tornam as pessoas criminosas, encontrando causas na baixa escolaridade, em processos psicológicos ou sociais, bem como na alta densidade populacional, desemprego e na falta de infraestrutura, aliada ao abandono pelo Estado das populações marginalizadas, conforme apontam Francisco Filho e Silva (2010).

Segundo Wortley e Townsley (2017), após o indivíduo adotar comportamento criminoso, a prática do crime é considerada mais ou menos inevitável, com menor ênfase na identificação do local e do momento específico da transgressão. Nesse cenário, a prevenção ao crime é alcançada por meio da modificação do comportamento dos infratores, mediante, por exemplo, da eliminação de desvantagens sociais e, se tiverem cometido delitos, por intermédio da oferta de programas de reabilitação. Entretanto, essas ações estão fora do alcance da prática policial (Wortley; Townsley, 2017).

Contudo, a criminologia ambiental adota uma perspectiva distinta. Aqui, o crime é o centro de atenção. Nesta abordagem, o infrator é apenas um componente de um evento criminoso, e o processo pelo qual os infratores se tornam o que são tem pouca relevância.

Ao invés disso, o foco recai sobre a dinâmica do crime: onde, quando, quem, o que, por que e como ocorreu (Wortley; Townsley, 2017).

A criminologia ambiental explora as maneiras pelas quais a situação imediata proporciona oportunidades que explicam a distribuição padronizada do crime, como a falta de proteção de alvos, por exemplo, sendo extremamente valioso no âmbito policial. Seu objetivo principal reside na prevenção de crimes. Compreender o papel dos ambientes na modelagem de um evento criminoso é uma poderosa ferramenta na alocação de recursos humanos e financeiros na investigação, no controle e na prevenção da criminalidade (Clarke; Eck, 2016; Wortley; Townsley, 2017).

Conforme delineado por Andresen (2014), a criminologia ambiental abrange quatro teorias, a saber: Teoria das Atividades Rotineiras, Teoria da Escolha Racional, Teoria da Geometria e Teoria do Padrão do Crime, todas elencadas no Quadro 1. É importante ressaltar que a descrição detalhada dessas teorias está além do escopo deste trabalho.

Quadro 1. Explicação sumária das teorias integrantes da criminologia ambiental

Teoria	Explicação
Teoria das atividades rotineiras	Para que um crime ocorra deve haver convergência, no tempo e espaço, de três elementos: um infrator motivado, um alvo adequado (pessoa, local ou produto) e ausência de um guardião capaz de impedir o crime (pessoa ou equipamento que desencoraje a prática do delito)
Teoria da escolha racional	Busca explicar a ocorrência de crimes ao analisar o processo cognitivo que leva um indivíduo a cometer um delito. A decisão de cometer o crime é influenciada pelo que é mais evidente e imediato, com pouca consideração por análises mais complexas de custo/benefício. O criminoso, nesse contexto, tende a negligenciar possíveis punições ou consequências de longo prazo, focando na recompensa imediata do ato criminoso ou no risco de ser impedido no momento da ação
Teoria da geometria do crime	Visa elucidar de que forma o ambiente construído influencia o padrão geográfico dos crimes. Além disso, pode ser interpretada como uma manifestação espacial da teoria das atividades rotineiras

Teoria	Explicação
Teoria do Padrão do Crime	É uma síntese das três teorias iniciais, destacando a interconexão entre elas para a compreensão do fenômeno criminal. Ela ressalta a natureza dinâmica do processo de tomada de decisão ao cometer um crime em um momento e local específicos

Fonte: Adaptado de Andresen (2014); Clarke; Eck, (2016)

Por meio da leitura do Quadro 1, nota-se que cada uma dessas teorias, individualmente, contribui para a compreensão do crime. Contudo, quando consideradas em conjunto, elas têm o potencial de oferecer uma representação abrangente do ambiente em que o crime ocorre. Conforme indicado por Andresen (2014), as teorias das atividades rotineiras e da geometria do crime sugerem a presença de locais com uma elevada concentração de atividade criminosa, ou seja, de *hotspots* criminais.

2.4. MAPEAMENTO DE *HOTSPOTS* CRIMINAIS

De acordo com Eck (2005), *hotspots* criminais são áreas específicas com uma incidência de crimes superior à média, em comparação com as regiões circundantes. A identificação dessas áreas é realizada por meio de análises estatísticas a partir de dados históricos que destacam padrões de criminalidade localizados. Percebe-se que a existência de *hotspots* criminais sugere a existência de “*coolspots*” criminais (locais com taxas de criminalidade inexistentes ou inferiores à média), assim como de áreas mais quentes que outras (Eck, 2005).

Dado que os crimes não se manifestam aleatoriamente nem de maneira uniforme no espaço, o mapeamento de *hotspots* criminais é usado como uma ferramenta básica de previsão de crimes. Isso decorre do fato de que criminosos, frequentemente, tendem a seguir os padrões fornecidos pelas oportunidades locais para cometer delitos (Eck, 2005; Perry *et al.* 2013)

Nessa perspectiva, Sherman (1995), ao analisar o histórico criminal de áreas e infratores, constatou que as previsões de crimes foram seis vezes mais precisas ao considerar o local. Destarte, a prática de mapeamento *hotspots* criminais auxilia as autoridades policiais na previsão de crimes e na alocação de seus recursos de forma mais eficaz, concentrando-se nas áreas onde a intervenção policial pode gerar o maior impacto na prevenção do crime (Chainey *et al.*, 2008; Perry *et al.*, 2013).

Por exemplo, em um estudo voltado para determinar a duração ideal de patrulhas policiais para prevenir crimes em *hotspots*, Christopher Koper (1995) *apud* Perry *et al* (2013) enfatizou a eficácia de paradas com duração de 13 a 15 minutos. Durante essas paradas, os policiais interagem com membros da comunidade, resultando na redução efetiva de delitos em áreas com alta concentração de atividades criminosas. Assim, a identificação de *hotspots* criminais possibilita um direcionamento mais eficiente das estratégias de policiamento, auxiliando na tomada de decisão e no direcionamento de recursos humanos e financeiros (Braga, 2005).

Chainey *et al.* (2008) enfatizam a relevância desse tipo de mapeamento na previsão de padrões espaciais de crimes, identificando o Mapeamento de Pontos, as Elipses Espaciais de Desvio Padrão, o Mapeamento Temático de Unidades Administrativas, o Mapeamento em Grid e a Estimativa de Densidade Kernel (EDK) como as técnicas mais comuns na criação de mapas de *hotspots* criminais, cada qual com suas particularidades e limitações.

O Quadro 9, exibido Apêndice II, resume cada uma dessas técnicas. É fundamental destacar que cada técnica de mapeamento de *hotspots* requer a definição de parâmetros específicos para a produção de mapas que reflitam, com precisão, os padrões de distribuição espacial do crime observados na região, contribuindo, assim, para previsões mais precisas. Entretanto, a determinação desses parâmetros não será discutida neste trabalho.

As técnicas de mapeamento de *hotspots* criminais mencionadas no Quadro 9 produzem resultados diferentes em termos de localização, tamanho e formato das áreas identificadas como *hotspots*. Adicionalmente, Chainey *et al.* (2008), destacaram que as capacidades preditivas do mapeamento de *hotspots* variam entre as técnicas empregadas e de acordo com o tipo de crime.

Apesar de úteis na previsão de crimes, as abordagens tradicionais de mapeamento de *hotspots* criminais tendem a supor que o crime permanecerá estático, desconsiderando sua natureza dinâmica ao longo do tempo. Ao se basear exclusivamente em registros passados de crimes, essas técnicas negligenciam o contexto do ambiente construído ao tentar antecipar ocorrências futuras (Drawve, 2016). Tais limitações podem ser superadas com a adoção da modelagem *Risk Terrain Modelling* (RTM).

A modelagem RTM incorpora em sua análise as características ambientais que se acredita contribuir para a formação de áreas de risco, indo além dos registros de crimes passados. A análise do crime deixa de ser estática e passa a ser dinâmica, pois, caso haja

uma mudança no padrão de crime, o RTM poderá prever onde ele ocorrerá, inovando ao considerar fatores ambientais como elementos de risco para o crime (Drawve, 2016).

Cabe ressaltar que nem todas as áreas de risco serão palco de crimes, mas sim que suas características ambientais as tornam mais propensas à ocorrência de atividades criminosas, direcionando recursos e intervenções preventivas de forma mais eficaz, contribuindo para a redução da criminalidade e o aumento da segurança pública (Drawve, 2016).

2.5. MÉTRICAS DE AVALIAÇÃO DE MAPEAMENTO DE *HOTSPOTS* CRIMINAIS

Antes de discorrer sobre o RTM, é fundamental ressaltar a relevância das métricas para avaliação da eficácia preditiva dos mapeamentos de *hotspots* criminais. Conforme Hart (2021) observou, as estratégias de mapeamento de *hotspots* podem ter sua eficácia comprometida caso as previsões ou estimativas sobre a ocorrência de crimes não sejam precisas e confiáveis.

Nesse contexto, várias métricas são comumente empregadas para avaliar a confiabilidade das previsões geradas pelos métodos de mapeamento de *hotspots* criminais. Essas métricas incluem a Taxa de Acerto (*Hit Rate* - HR), o Índice de Acurácia Preditiva (*Predictive Accuracy Index* - PAI) e o Índice de Taxa de Recaptura (*Recapture Rate Index* - RRI). Além dessas, outras métricas desempenham um papel crucial na orientação do planejamento e na execução das atividades policiais em *hotspots* criminais. Destacam-se entre elas a Relação Área-Perímetro (*Area-to-Perimeter Ratio* - APR) e o Índice de Variabilidade Dinâmica (*Dynamic Variability Index* - DVI).

A Taxa de Acerto (ou *Hit Rate* - HR) é uma métrica comumente empregada na avaliação da acurácia dos *hotspots*. Ela é definida como a proporção de todos os eventos criminais que ocorrem no tempo 2 e que estão contidos nos *hotspots* criados a partir dos dados do tempo 1. Seu valor é expresso em porcentagem (Adepeju et al., 2016). A HR é especialmente útil na análise direta da capacidade preditiva dos métodos de mapeamento *hotspot* (Hart, 2021).

Em razão de algumas limitações da Taxa de Acerto, foi desenvolvido o Índice de Acurácia Preditiva (PAI). Este índice é calculado como a razão entre a Taxa de Acerto e o percentual da área de estudo definido como um *hotspot* criminal. Valores mais altos de PAI indicam uma maior acurácia preditiva, enquanto pontuações mais baixas refletem previsões

menos acuradas. Embora o PAI seja considerado uma melhoria em relação a taxa de acerto, ele não considera as mudanças nos padrões de crime ao longo do tempo.

Levine (2008) argumentou que é possível ser acurado sem ser preciso, razão pela qual ele propôs a inclusão do Índice de Taxa de Recaptura (RRI) para avaliar a precisão da capacidade dos *hotspots* em "capturar" crimes. O RRI compara a mudança na taxa de precisão entre o período de tempo 2 e o período de tempo 1, sendo frequentemente definido como a razão entre o PAI no tempo 2 e o PAI no tempo 1 (Levine, 2008; Drawve, 2016).

Um valor inferior a 1,0 é interpretado como uma redução na precisão dos *hotspots* em prever crimes de um período para o outro, enquanto um valor superior a 1,0 é interpretado como um aumento na precisão dos *hotspots* na previsão de crimes entre os períodos (Levine, 2008). Com isso, o RRI também avalia se os *hotspots* de crime estão se tornando mais ou menos densos entre os tempos 1 e 2. De acordo com Drawve (2016) o RRI desempenha um papel complementar ao apoiar o PAI. Enquanto o PAI avalia a acurácia, o RRI foca na precisão.

Considerando as limitações de recursos das polícias militares, é impraticável patrulhar constantemente todos os *hotspots* de crime, especialmente se forem numerosos. É compreensível que, quanto mais compactos e concentrados forem os *hotspots* criminais, mais eficiente será a sua vigilância, o que pode melhorar a eficácia das estratégias de policiamento na redução do crime e também no controle de custos. A Relação Área-Perímetro (APR) é uma das métricas empregadas para avaliar a concentração de *hotspots* criminais fornecendo *insights* para a alocação eficiente de recursos e o desenvolvimento de estratégias mais eficazes (HART, 2021).

A APR, calculada ao dividir a área de um *hotspot* pelo seu perímetro, é um reflexo da concentração da atividade criminosa. Valores altos sugerem uma distribuição mais compacta do crime, o que facilita o patrulhamento dessas áreas e permite uma alocação mais eficiente de recursos, além de respostas mais rápidas. Por outro lado, APRs menores indicam dispersão, apresentando desafios adicionais para o policiamento, o que demanda uma abordagem mais abrangente por parte das autoridades policiais (HART, 2021)


Para a avaliação da estabilidade dos *hotspots* criminais ao longo do tempo, foi criado o Índice de Variabilidade Dinâmica (DVI). Este índice é uma métrica que leva em conta as alterações na estabilidade dos *hotspots* ao longo do tempo, conforme definido pela Equação 1 definida por Adepeju et al (2016). A Figura 1 pode auxiliar na visualização desse conceito. Quanto mais alto for o valor de DVI, menor será a estabilidade nos pontos críticos de crime, o que pode tornar o patrulhamento mais desafiador.

$$DVI = \frac{E}{(E+R)} \quad \text{(Equação 1)}$$

Em que:

- E = células do grid de *hotspot* recém-surgidas no tempo 2
- R = número de células de *hotspot* que são recorrentes no tempo 1 e 2

Figura 1. Ilustração da métrica DVI



Fonte: Hart (2021).

Na Figura 1, são apresentados os *hotspots* de crime para dois períodos consecutivos. As células do grid em cinza claro indicam as áreas de *hotspot* que se repetem do primeiro período para o próximo, enquanto as células em cinza escuro correspondem aos *hotspots* que estão desaparecendo, e as células pretas representam os *hotspots* que surgiram no período 2.

Saber se as previsões de padrões de crime são estáveis ou fluidas ao longo do tempo pode ter implicações para as estratégias de policiamento. Por exemplo, se os *hotspots* criminais forem identificados como áreas compactas, podem parecer bons alvos para intervenções. Entretanto, se forem altamente instáveis ao longo do tempo, as intervenções poderão ser ineficazes se forem implementadas no momento errado. Assim, compreender os padrões temporais de estabilidade dessas áreas é fundamental para o sucesso das estratégias de policiamento (HART, 2021).

2.6. RISK TERRAIN MODELLING (RTM)

Desenvolvido por Caplan *et al* (2011), o *Risk Terrain Modeling* (RTM) é um método preditivo baseado nas técnicas tradicionais de mapeamento de *hotspots*, na criminologia ambiental (Drawve, 2016; Valasik *et al*, 2019) e no policiamento orientado para o problema (Caplan; Kennedy, 2011). Ele avalia e identifica locais com maior propensão a ocorrências de crime no futuro, com base na interação entre os fatores de risco presentes na área de estudo (Perry *et al*, 2013).

Além dessa aplicação, é importante mencionar que o RTM, como técnica de análise de risco espacial, também pode ser utilizado na investigação de outras questões socioambientais. Caplan, Kennedy e Neudecker (2020) aplicaram o RTM, por exemplo, para analisar os dados do surto de cólera que ocorreu em Londres em 1854, conforme investigado por John Snow. Eles confirmaram os resultados de Snow, demonstrando uma relação estatisticamente significativa entre a localização dos poços de água contaminados e as pessoas doentes.

Quando comparado a outras técnicas de mapeamento de *hotspots* (ver Quadro 9), o RTM pode produzir resultados qualitativamente semelhantes. Contudo, em termos analíticos, esses métodos diferem (Perry *et al*, 2013). Por exemplo, o EDK ou as Elipses Espaciais de Desvio Padrão baseiam-se exclusivamente no agrupamento de registros criminais (clusters) para prever eventos futuros.

Por outro lado, o RTM incorpora não apenas essas informações, mas também fatores riscos sociais, econômicos, ambientais e físicos da região em sua análise, o que pode contribuir para previsão da criminalidade (Drawve, 2016), proporcionando uma perspectiva em que o crime é menos determinado por eventos passados e mais pelo contexto (Kennedy *et al*, 2011; Marchment; Gill, 2021).

Valasik *et al*. (2019) destacam que o RTM não se limita a prever a ocorrência de crimes, mas também fornece *insights* sobre porque certas áreas apresentam alto risco de criminalidade. Ao considerar e ponderar uma variedade de fatores ambientais, sociais e econômicos correlacionados com padrões espaciais de eventos de interesse, o RTM oferece uma compreensão mais abrangente da dinâmica deste fato em uma região específica. Essa abordagem não apenas identifica áreas de risco, mas também ajuda a elucidar os mecanismos que contribuem para a propensão ao crime (fenômeno social objeto de estudo deste trabalho). Assim, o RTM ressalta a importância do ambiente na

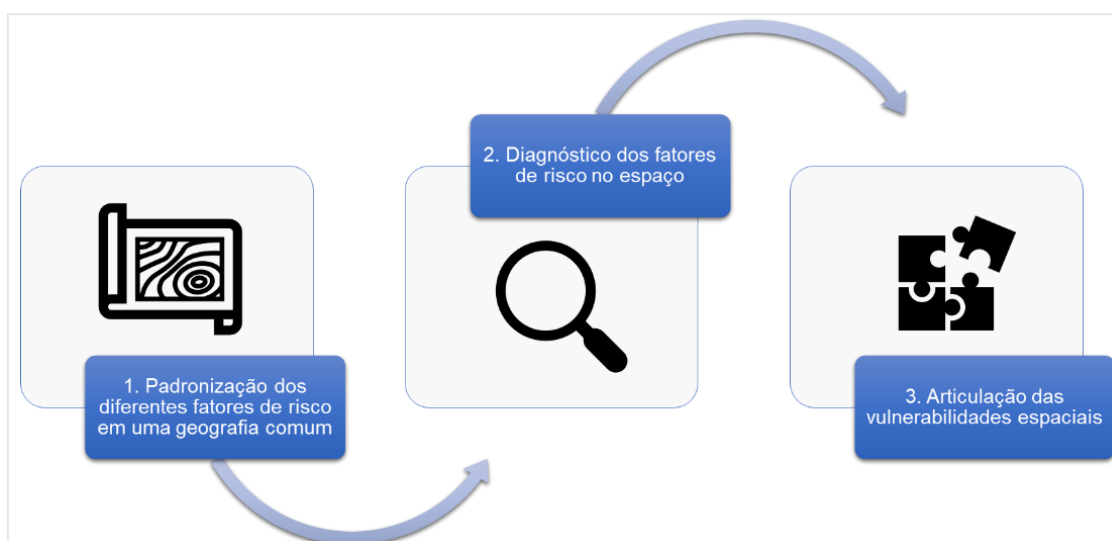
compreensão do fenômeno criminal e no desenvolvimento de estratégias preventivas eficazes (Kennedy; Caplan; Piza, 2011).

É fundamental destacar que os fatores de risco por si só não são causas diretas do crime. Eles indicam apenas os locais onde, sob certas condições, o risco de crime ou vitimização é mais elevado. Embora todos os locais possam ser vulneráveis até certo ponto, alguns são mais suscetíveis que outros devido à combinação de fatores de risco e a ocorrências criminais anteriores. Isso aumenta a probabilidade de um local se tornar mais vulnerável ao crime (Caplan; Kennedy, 2011; Kennedy *et al.*, 2016).

Para identificar tais áreas, são criadas camadas de mapas no Sistema de Informações Geográficas (SIG), representando a influência espacial de cada fator de risco de crime. Somente os fatores estatisticamente significativos são usados na modelagem RTM. Posteriormente, essas camadas são combinadas para formar um mapa composto, refletindo a presença, ausência ou intensidade da criminalidade na paisagem. Regiões com valores acima da média indicam maior probabilidade de ocorrências criminais futuras, ou seja, são *hotspots* criminais. (Perry *et al*, 2013; Caplan *et al*, 2017; Dugato; Calderoni; Berlusconi, 2020).

Inicialmente, o processo de modelagem RTM se baseia em três passos principais, conforme apresentado pela Figura 2.

Figura 2. Representação sucinta do processo de modelagem RTM



Fonte: Adaptado de Kennedy e Dugato (2018)

De acordo com a Figura 2, a primeira etapa começa com a padronização dos fatores de risco em um espaço geográfico específico/comum, que pode ser uma cidade ou região.

Durante esta etapa, são criadas camadas que representam a área de estudo e os fatores de risco associados ao crime. Em seguida, essas camadas são subdivididas em grids (espaços padronizados de mesma dimensão). É importante destacar que as dimensões de cada grid podem variar, dependendo do tipo de estudo e da capacidade de processamento do computador (Limeira, 2022).

Nesta etapa também são examinados os modos de influência dos fatores de risco na área de estudo. Essa análise é fundamental para compreender melhor como os fatores de risco afetam a ocorrência de crimes na região. Segundo Marchment e Gill (2021), a influência pode ser interpretada com base na proximidade ou na densidade do fator de risco presente no espaço. A proximidade é definida como a presença de um fator de risco a uma distância específica do evento. Por outro lado, a densidade é determinada pela concentração do fator de risco em relação ao evento estudado (Marchment; Gill, 2021).

Na segunda fase, realiza-se o diagnóstico dos fatores de risco previamente escolhidos. Nesse estágio, um procedimento estatístico é empregado para identificar e escolher os fatores de risco que estão significativamente associados ao tipo de crime, os quais serão aplicados na modelagem RTM. Conforme observado por Dugato, Calderoni e Berlusconi (2020), essa etapa é fundamental para avaliar a confiabilidade dos pressupostos teóricos que embasaram a seleção inicial dos fatores de risco. Assim, diversos estudos utilizaram os seguintes testes estatísticos:

- A regressão logística ou binomial (Kennedy *et al*, 2011);
- A regressão de Poisson (Dugato; Calderoni; Berlusconi, 2020) e;
- A regressão binomial negativa (Kennedy *et al*, 2016; Drawve, 2016; Caplan *et al*, 2017)

Conforme destacado por Perry *et al.* (2013), as análises de regressão são uma ferramenta valiosa e amplamente utilizada na investigação de questões relacionadas ao crime. Essas análises estabelecem uma relação matemática entre a variável a ser prevista e as variáveis explicativas, também conhecidas como variáveis independentes, visando alcançar significância estatística.

O Quadro 2, apresenta uma síntese dos métodos de regressão mencionados, oferecendo uma visão abrangente de cada um deles.

Quadro 2. Síntese dos métodos de regressão utilizados na modelagem RTM

Método de regressão	Síntese do método de regressão
Regressão logística ou binomial	Técnica estatística que modela a relação entre uma variável dependente binária (ou seja, uma variável que possui apenas duas categorias, como "sim" ou "não", "0" ou "1") e uma ou mais variáveis independentes. Ela é usada para prever a probabilidade de um evento binário com base nas variáveis independentes
Regressão de Poisson	Técnica estatística empregada para investigar como variáveis independentes afetam a frequência de um evento em um período de tempo ou espaço específico. Amplamente utilizada na análise de dados de contagem, essa abordagem pressupõe uma distribuição de Poisson (a média e a variância dos dados são iguais). É aplicada quando os eventos ocorrem independentemente e mantêm uma taxa média constante ao longo do tempo ou espaço. Seu propósito principal é estimar os parâmetros do modelo para prever a média de ocorrências sob diferentes condições independentes
Regressão binomial negativa	Técnica estatística utilizada na análise de dados de contagem, visando compreender como os fatores independentes influenciam a contagem de eventos raros ou incomuns em um determinado período de tempo ou espaço. Ela fornece estimativas dos parâmetros do modelo para realizar previsões e análises. Essa abordagem é particularmente útil quando há uma considerável variabilidade em relação à média dos dados, tornando inadequada a representação por uma distribuição binomial padrão, o que sugere uma superdispersão

Fonte: Adaptado de Long (1997).

Na terceira fase, os fatores de risco escolhidos na etapa anterior são integrados em um Sistema de Informações Geográficas (SIG) para criar um mapa de risco composto, destinado a identificar células do grid com maior vulnerabilidade à ocorrência de crimes. Neste mapa, cada célula do grid recebe um Valor de Risco Local (VRL). Esse valor é calculado pela soma ponderada dos termos obtidos na segunda etapa, por meio da Equação 2 proposta por Caplan *et al* (2015).

$$VRL = \frac{Exp(\beta_0 + \sum_{i=1}^n X_{gf} \beta_f)}{Exp(\beta_0)}, \forall g \in (1, n), g \in \mathbb{N} \quad \text{(Equação 2)}$$

Onde:

- VRL : valor de risco local
- β_0 : coeficiente de regressão do intercepto
- X : valor de risco de cada fator
- β_f : coeficiente de regressão do fator de risco
- f : fator de risco
- g : posição do grid

O VRL é uma taxa que indica a probabilidade de um local ser palco de atividades criminosas. Ele destaca regiões onde a probabilidade de ocorrência de crimes é elevada, dependendo da abordagem de classificação empregada. Compreender os motivos e os locais de persistência do crime ao longo do tempo oferece oportunidades para direcionar os serviços de prevenção às áreas mais necessitadas (Kennedy; Dugato, 2018).

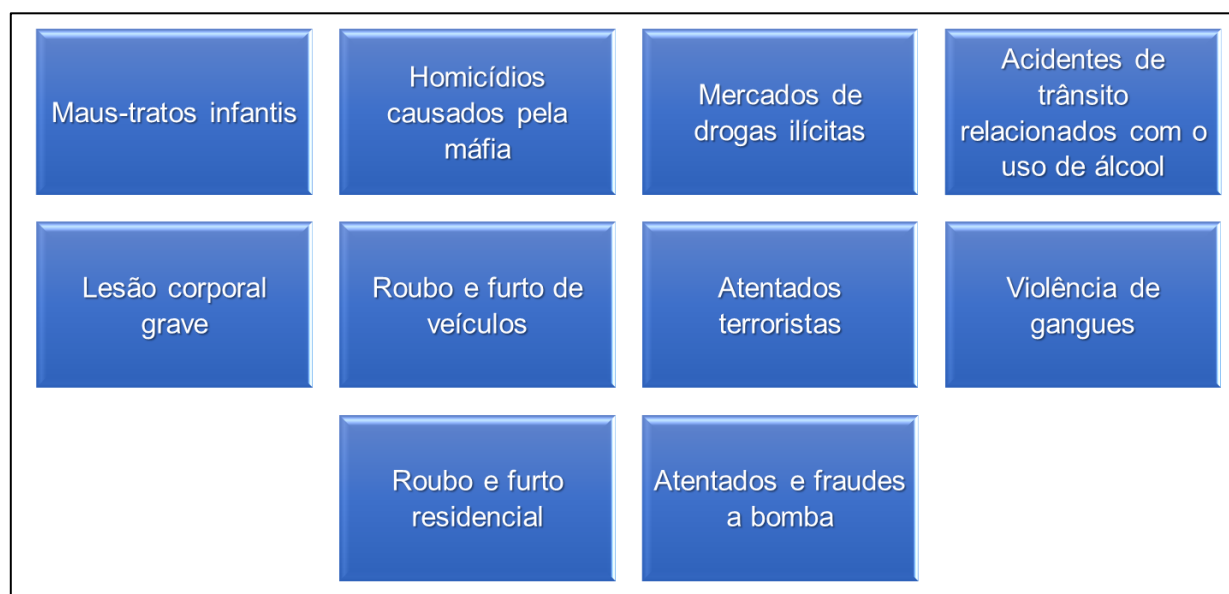
Considerando o horizonte de previsão, estudos realizados por diferentes pesquisadores como Caplan e Kennedy (2011) e Moreto, Piza e Caplan (2014), entre outros, indicam que períodos de três e seis meses são relevantes para análise. Além disso, alguns estudos estendem o horizonte de previsão para um ano, como apontado por Daley *et al.* (2016) e Dugato, Calderoni e Berlusconi (2020).

Perry *et al.* (2013) descreveram o RTM como uma técnica genuinamente preditiva, flexível e adaptável permitindo a utilização de diversos métodos, bem como para análise de diversos eventos como pode ser observado no estudo de Caplan, Kennedy e Neudecker (2020). Segundo Drawve (2016), o RTM tem se mostrado uma técnica de mapeamento *hotspot* mais precisa e confiável em virtude do seu método de análise.

Em uma meta-análise, Marchment e Gill (2021) revisaram uma variedade de estudos (Figura 3) que demonstraram a eficácia do RTM na previsão de ocorrências criminais. Diversos países, incluindo Estados Unidos, Itália, Colômbia, Canadá, Espanha, Áustria, Irlanda do Norte, Turquia e Japão, foram mencionados por Marchment e Gill (2021) como locais onde essa técnica tem sido aplicada com sucesso.

Dentre os estudos pesquisados por Marchment e Gill (2021), não foi observado nenhum artigo que tenha empregado a modelagem RTM na previsão de crimes ambientais, conforme pode ser visto na Figura 3. Essa falta ou escassez de estudos criminológicos associados ao meio ambiente pode ser atribuído a um início tardio dos estudos criminológicos sobre as ciências ambientais (Konrad *et al.*, 2020), sendo considerada uma área marginal dentro da criminologia (Cowan *et al.*, 2020).

Figura 3. Temas de pesquisas que incorporaram a modelagem RTM na sua metodologia para prever ocorrências criminais



Fonte: Adaptado de Marchment e Gill (2021)

Conforme apontado Konrad *et al.* (2020) a criminologia surgiu nas ciências ambientais no final das últimas décadas do século XX, a partir da compreensão de que os danos ao meio ambiente compõe uma área da investigação criminológica. A esse novo ramo da criminologia convencionou-se chamar de criminologia verde ou *green criminology*, termo majoritário no âmbito internacional.

A criminologia verde prevê o exame multidisciplinar dos delitos ambientais, utilizando perspectivas pouco adotadas em pesquisas criminológicas (Cowan *et al.*, 2020) funcionando como uma ferramenta para investigar, estudar, analisar e lidar com causas e consequências de crimes e danos ambientais, muitas vezes ignorados, apesar do seu potencial lesivo e conexões com outras atividades ilícitas (Konrad *et al.*, 2020).

Passos, Pinheiro e Teixeira (2023), em sua pesquisa intitulada "Tensões de Poder: a ausência estatal como elemento propulsor do Primeiro Comando da Capital (PCC) e seus avanços na Amazônia Brasileira", apresentaram os problemas resultantes da expansão e consolidação do PCC e de outras facções criminosas na região Amazônica Brasileira.

Além das preocupações com a segurança pública, Passos, Pinheiro e Teixeira (2023) destacaram os efeitos colaterais da presença dessas organizações criminosas sobre o meio ambiente, destacando o aumento do desmatamento ilegal na Floresta Amazônica. Cabe destacar que o desmatamento ilegal é um tipo penal abordado nos artigos 38, 38-A, 39, 40, 48 e 50-A da Lei nº 9.605/1998, conhecida como Lei de Crimes Ambientais.

2.7. DESMATAMENTO

Antes de discutir o conceito e os problemas decorrentes do desmatamento, é interessante saber o conceito de floresta e conhecer a sua importância para todo o ser vivo. Segundo Coutinho (2016), uma floresta é uma vegetação densa composta por árvores cujas copas formam um "teto", conhecido como dossel ou copa.

Segundo a Organização das Nações Unidas para a Alimentação e a Agricultura (FAO, 2020), uma floresta é definida como uma área que contém árvores com altura mínima de 5,0 metros, cobrindo mais de 0,5 hectares e uma cobertura de copa de mais de 10%. Elas abrigam aproximadamente 60% das espécies de plantas vasculares, 80% das espécies de anfíbios, 75% das espécies de aves, 68% das espécies de mamíferos, além de fungos e invertebrados (FAO, 2022).

As florestas desempenham serviços ecossistêmicos fundamentais que têm um impacto significativo no bem-estar humano. Esses serviços incluem a provisão de alimentos, medicamentos, produtos madeireiros e não madeireiros; a regulação do clima, qualidade do ar, controle de doenças, pragas e ameaças naturais; a purificação da água e a conservação do solo. Além disso, as florestas oferecem oportunidades para recreação, ecoturismo e ciclo de nutrientes (MEA, 2005; Cardinale *et al.*, 2012; FAO, 2022).

Portanto, é evidente o papel vital das florestas na preservação e conservação de todas as formas de vida na Terra. Contudo, é crucial ressaltar que todos esses serviços, bem como toda a biodiversidade do mundo, estão ameaçados pelo desmatamento ou desflorestamento.

Conforme Mawalagedara e Oblesby (2012) indicam, o desmatamento se refere à remoção da cobertura vegetal nativa, principalmente em áreas florestais, o que, segundo Ritchie e Roser (2021), resulta na conversão permanente da cobertura nativa para outros usos, acarretando uma série de impactos ambientais, sociais e econômicos. Geist e Lambin (2001) destacam que o desmatamento é principalmente causado pelas atividades humanas.

De acordo com Ritchie e Roser (2021), cerca de 10.000 anos atrás, mais da metade das áreas habitáveis da Terra eram cobertas por florestas, enquanto a outra parte consistia em pastagens e arbustos selvagens. A partir da primeira metade desse período até o ano de 2018, a região antes coberta por vegetação nativa foi gradualmente transformada em pastagens, áreas agrícolas e zonas urbanas, com destaque para a expansão das pastagens.

A partir da segunda metade do século XVIII, durante a Revolução Industrial, houve um aumento substancial da capacidade produtiva e no consumo de recursos naturais em uma escala até então inédita (Franco; Druck, 1998), o que resultou em uma maior demanda por terra e uma crescente pressão sobre as florestas.

Ao examinar a relação econômica entre os benefícios públicos e privados das florestas, Bush e Gallon (2017) observaram que o desmatamento ultrapassa o ideal social traduzido pelo alcance de um equilíbrio sustentável entre as necessidades econômicas e ambientais. Segundo estes autores, aqueles que se beneficiam do uso da terra priorizam os ganhos privados provenientes do uso das florestas devido aos retornos econômicos imediatos, em detrimento dos benefícios públicos, como os serviços ecossistêmicos, resultando no aumento das taxas de desmatamento.

Nessa perspectiva, a FAO (2022) projetou para o ano de 2060 um aumento de 190 bilhões toneladas no consumo global de recursos naturais, excedendo o dobro da quantidade de recursos naturais consumidos em 2017 (92 bilhões). Esse aumento pode ter um impacto significativo na natureza, representando uma ameaça tanto para a biodiversidade quanto para o bem-estar humano.

O desmatamento contribui para a fragmentação florestal, dividindo áreas florestais contínuas em fragmentos isolados de tamanhos diversos, separados por paisagens alteradas, como pastagens e plantações (Fahrig, 2003). Além disso, a fragmentação reduz a conectividade entre os habitats, dificultando o movimento e a dispersão de espécies, o que pode levar à diminuição da diversidade genética e ao aumento da vulnerabilidade da biodiversidade (Rambaldi; Oliveira, 2003).

Green *et al.* (2019a) *apud* FAO (2020) observaram uma redução de 53% nas espécies de vertebrados que residem em florestas entre 1974 e 2014. Recentemente, este número foi atualizado. De acordo com a *World Wide Fund for Nature* (WWF, 2022), entre 1970 e 2018, foi registrada uma queda de 79% nessas espécies, destacando os riscos enfrentados pela biodiversidade de animais vertebrados florestais.

Nesse contexto, Cardinale *et al.* (2012) concluíram que a perda da biodiversidade pode reduzir a eficiência dos ecossistemas na produção de biomassa, na decomposição e na reciclagem de nutrientes. Além disso, destacaram que os impactos da redução da biodiversidade podem ser significativos o suficiente para rivalizar com outros fatores globais de mudança ambiental, como as mudanças climáticas. Também enfatizaram que a perda da biodiversidade pode resultar no aumento da frequência de incêndios florestais e na propagação de doenças (Cardinale *et al.*, 2012).

Sala *et al.* (2000) empregaram modelagem para analisar os possíveis efeitos das atividades humanas na biodiversidade de diversos ecossistemas terrestres e de água doce em diferentes biomas globais. Identificaram cinco principais fatores que influenciam essas mudanças e delinearão três cenários para a biodiversidade até 2100. Destacaram que a mudança no uso do solo é o principal fator de impacto na biodiversidade, seguido pelas mudanças climáticas e aumento de CO₂ na atmosfera.

Adicionalmente, Miller e Spoolman (2015) destacam que o desmatamento resulta na redução da fertilidade do solo, devido à erosão, e no assoreamento de corpos d'água. Além dos impactos na biodiversidade, o desflorestamento também afeta diretamente os seres humanos, comprometendo serviços ecossistêmicos vitais para a saúde e a economia.

O fornecimento de alimentos e de fármacos; a regulação do clima, da qualidade do ar, de doenças, de pestes e de ameaças naturais; a purificação da água e a proteção do solo; a recreação, o ecoturismo e a ciclagem de nutrientes são exemplos de serviços ecossistêmicos que a natureza fornece à humanidade de forma gratuita que podem ser impactados pelo desmatamento (MEA, 2005; Cardinale *et al.*, 2012; EMBRAPA, 2018; FAO, 2022).

Do ponto de vista econômico, a diminuição das chuvas, associada ao desmatamento no sul da Amazônia brasileira, foi destacada pela FAO (2022) como um fator que pode acarretar prejuízos anuais estimados em mais de US\$ 1 bilhão para a agricultura do país até 2050. Isso evidencia os impactos negativos que o desmatamento pode ter sobre a economia global.

Diante disso, é fundamental adotar medidas imediatas para mitigar os efeitos nocivos do desmatamento, visando preservar a diversidade biológica, garantir a continuidade dos serviços ecossistêmicos e promover um crescimento econômico sustentável. Entre as ações, destaca-se o monitoramento e mapeamento das florestas, método essencial para acompanhar as mudanças na cobertura florestal, identificar áreas de desmatamento e degradação, e implementar políticas de conservação eficazes cruciais para a biodiversidade, o clima e a economia global.

O monitoramento florestal ganhou destaque a partir de 1972, com o lançamento do primeiro satélite Landsat e os avanços nas tecnologias de sensoriamento remoto e SIG, proporcionando uma visão mais detalhada e precisa das florestas globais (Holmgren; Thuresson, 2008). No Brasil, diversas iniciativas de monitoramento dos biomas foram criadas, visando mapear o uso e a cobertura da terra, identificar desmatamentos para apoiar a fiscalização e monitorar mudanças no uso e cobertura da terra (Rosa, 2021).

Entre essas iniciativas, tanto governamentais quanto não governamentais, destacam-se: o Projeto de Monitoramento do Desmatamento por Satélite na Amazônia Legal e no Cerrado (PRODES); o Sistema de Detecção do Desmatamento em Tempo Real (DETER) na Amazônia e no Cerrado; o Sistema de Alerta de Desmatamento (SAD) para toda Amazônia brasileira; o Projeto TerraClass para a Amazônia Legal e o Cerrado; o Mapeamento da Cobertura Vegetal da Bacia do Alto Paraguai no Pantanal; o Atlas dos Remanescentes Florestais da Mata Atlântica e o Projeto MapBiomas (Rosa, 2021).

Todos esses esforços têm contribuído para a conservação e gestão dos recursos florestais no Brasil, facilitando a fiscalização e permitindo a identificação rápida e precisa de áreas desmatadas, contribuindo para a preservação da biodiversidade e dos serviços ecossistêmicos. Nesse sentido, é essencial conhecer quais são fatores (ou vetores) que impulsionam o desmatamento, com o objetivo de identificar antecipadamente áreas propensas ao desflorestamento, com o objetivo de direcionar ações de monitoramento e fiscalização mais efetivos.

2.8. VETORES DE DESMATAMENTO

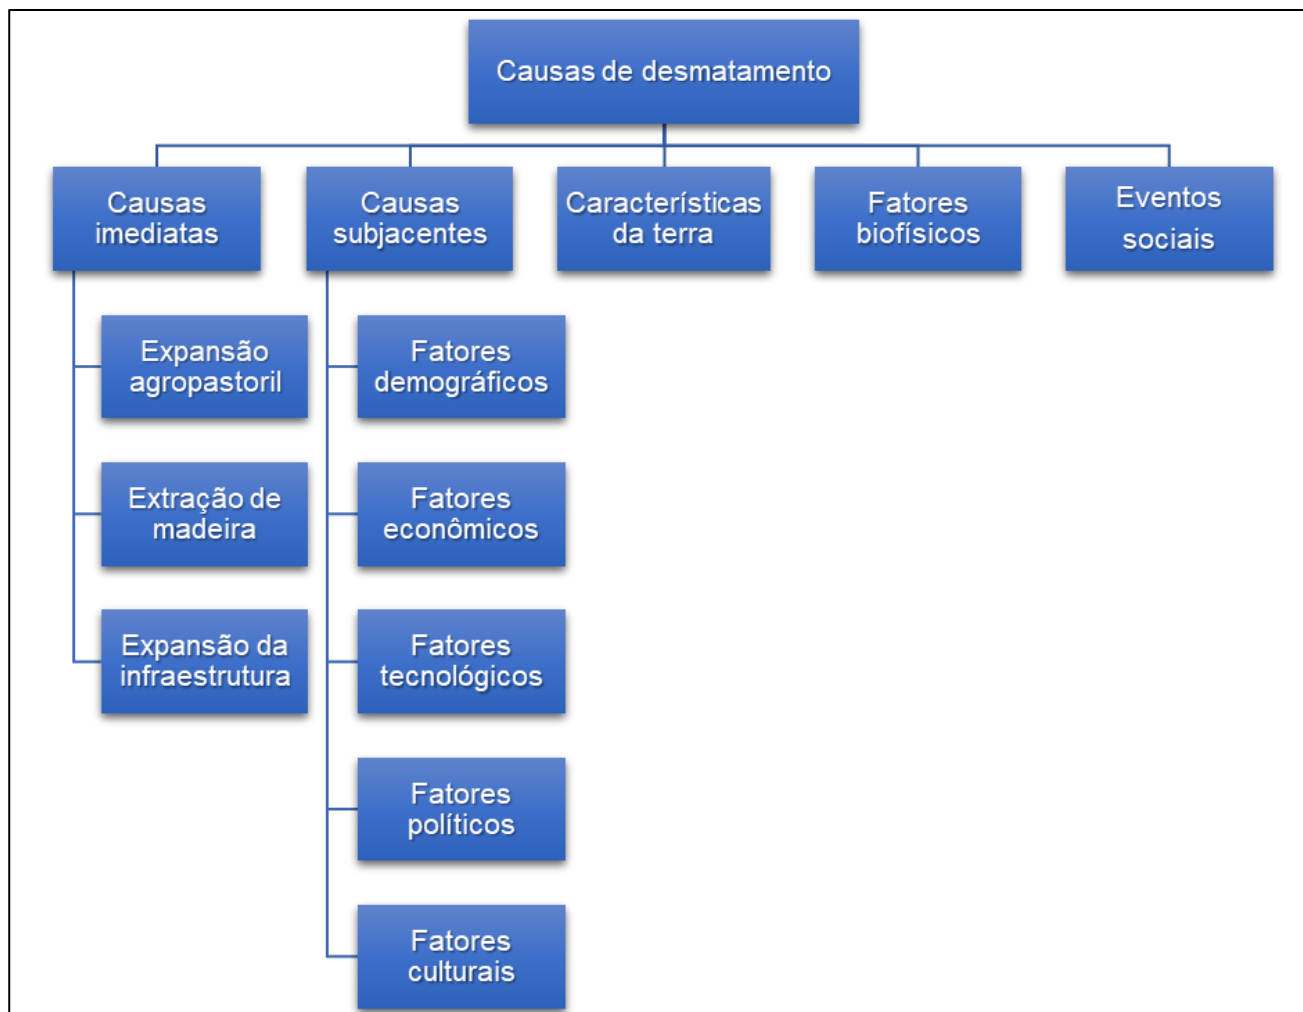
As teorias sobre os fatores que causam o desmatamento remontam a um modelo econômico proposto por Johann Heinrich von Thünen, economista alemão nascido em 1783. Segundo ele, os fatores econômicos são determinantes na conversão de florestas em áreas agrícolas. Embora a economia continue a ser um fator determinante nos padrões contemporâneos de desmatamento (Bush; Gallon, 2017), há outros elementos que precisam ser considerados na análise da dinâmica do desmatamento em florestas tropicais (Scriciu, 2007).

Geist e Lambin (2001) observaram que, apesar dos esforços de estudiosos e agências governamentais, as correlações entre o desmatamento em florestas tropicais e suas causas são diversas e variáveis, não revelando nenhum padrão distinto, o que torna a sua análise complexa. Isto dificulta o desenvolvimento de políticas universais de combate ao desmatamento nas florestas tropicais, conforme apontado por Folmer e Kooten (2006) *apud* Arraes, Mariano e Simonassi (2012).

Contudo, Hosonuma *et al.* (2012) argumentam que identificar essas causas e suas correlações é fundamental para a implementação de estratégias de combate ao desmatamento. Nesse sentido, a sistematização de causas do desmatamento proposta por

Geist e Lambin (2001), pode auxiliar na identificação dos fatores que contribuem para o desmatamento em florestas tropicais. A Figura 4 ilustra essa sistematização.

Figura 4. Sistematização das principais causas de desmatamento em florestas tropicais proposta por Geist e Lambin (2001)



Fonte: Adaptado de Geist e Lambin (2001).

De acordo com a Figura 5, as causas do desmatamento são divididas em cinco: causas imediatas, causas subjacentes, características da terra, fatores biofísicos e eventos sociais. As causas imediatas resultam das atividades humanas que impactam diretamente o meio ambiente, ocasionando a conversão imediata da floresta em outros tipos de cobertura do solo. Essas causas são classificadas em três principais grupos: expansão agropastoril, extração de madeira e expansão da infraestrutura (Geist; Lambin, 2001).

As causas subjacentes, também conhecidas como forças motrizes, compreendem um conjunto complexo de variáveis que sustentam as causas imediatas. Elas são

agrupadas em cinco categorias, sendo: fatores demográficos, econômicos, tecnológicos, políticos e culturais (Geist; Lambin, 2001).

As características da terra referem-se a uma série de atributos físicos locais que exercem influência sobre o desmatamento, como o relevo, por exemplo. Sua análise implica em uma abordagem mais estática do meio ambiente, visto que elas não mudam com frequência ou de forma rápida, ao contrário dos fatores biofísicos e eventos sociais, considerados mais dinâmicos. Estes últimos, desempenham o papel de catalisadores, podendo intensificar ou reduzir a taxa de desmatamento, resultando em mudanças repentinas na região. No entanto, em certas ocasiões, alguns fatores biofísicos, como os incêndios florestais, podem agir como causas imediatas de desmatamento (Geist; Lambin, 2001).

Cada uma das causas mencionadas na Figura 5 possui uma escala de alcance definida. No Quadro 3 são delineadas as escalas de influência das causas do desmatamento, acompanhadas de exemplos específicos de causas de desflorestamento em florestas tropicais.

Quadro 3. Nível de escala e exemplos de fatores (atividades específicas) relacionados com as causas de desmatamento em florestas tropicais

Causas do desmatamento tropical		Escala	Exemplos de fatores relacionados com o desmatamento de florestas tropicais
Causas imediatas	Expansão agropastoril	Local	Cultivo itinerante e permanente, criação de gado, processos de colonização e implantação de assentamentos rurais ou urbanos
	Extração de madeira		Extração de toras de madeira e de lenha, além da produção de carvão vegetal. Para todos os casos deve-se considerar a influência do corte (raso ou seletivo), bem como da modalidade de exploração (legal e ilegal) sobre as florestas
	Expansão da infraestrutura		Infraestrutura de transportes (rodovias, estradas, ferrovias, etc); Infraestrutura de mercado (supermercados, galpões, serrarias, etc); Serviços públicos (saneamento básico, redes elétricas, etc); Expansão de assentamentos (rurais, semi-urbanos, etc); Infraestrutura de empresas privadas (exploração de petróleo, implantação de hidrelétricas, mineração, etc)

Causas do desmatamento tropical		Escala	Exemplos de fatores relacionados com o desmatamento de florestas tropicais
Causas subjacentes	Fatores demográficos	Local, regional ou global	Pressão, crescimento, densidade e distribuição (irregular) populacional; Imigração etc.
	Fatores econômicos		Crescimento dos mercados; Aumento das exportações e dos lucros em moeda estrangeira; Aumento na demanda por bens de consumo e por serviços; Urbanização e industrialização; Falta de oportunidades de renda, desemprego, pobreza etc.
	Fatores tecnológicos		Agricultura de precisão, baixo nível de insumos tecnológicos, desperdícios no processamento de insumos madeireiros etc.
	Fatores políticos (Formais, informais e regimes de direito de propriedade)		Políticas formais (taxação, tarifas, créditos, subsídios, licenças, legislação etc.); políticas informais (corrupção, ilegalidade, má administração, política pró-desmatamento etc.); Regimes de direitos de propriedade
	Fatores culturais (Atitudes, valores e crenças)		Comportamento coletivo (Falta de preocupação com a coisa pública, despreocupação com o bem-estar dos outros e das gerações futuras etc.); Comportamento individual (Consumo crescente de materiais e energia - comportamento geralmente herdado etc.)
Características da terra	Local ou regional	Relacionadas ao solo (qualidade do solo boa/ruim da terra), à inclinação e a topografia (áreas planas ou suavemente inclinadas, áreas baixas), à água (localização de recursos hídricos), à vegetação (tamanho e fragmentação da floresta, densidade da vegetação)	
Fatores biofísicos		Relacionadas ao solo (Compactação, redução da fertilidade ou degradação), à água (baixa ou alta umidade, inundações), à vegetação (invasão de ervas daninhas, incêndios florestais)	
Eventos sociais		Guerra; Condições de saúde e crise econômica; deslocamentos populacionais abruptos (movimentos de refugiados); Falhas nas políticas governamentais etc.	

Fonte: Adaptado de Geist e Lambin (2001)

Após a análise do Quadro 3, torna-se evidente que as influências que afetam o desmatamento abrangem diversas escalas, desde o âmbito local até o global. Em nível local, elementos como a construção de estradas, práticas inadequadas de pecuária, exploração madeireira e agrícola têm um impacto notável no processo de desflorestamento. Em uma escala mais ampla, fatores como políticas governamentais e a demanda mundial por produtos agrícolas e madeireiros desempenham um papel crucial, exercendo influência sobre o desmatamento em múltiplas regiões do planeta.

Além disso, observa-se que certos elementos estão diretamente correlacionados ao desmatamento, enquanto outros não, especialmente aqueles vinculados às causas subjacentes. Kaimowitz e Angelsen (1998) *apud* Geist e Lambin (2001) afirmam que é mais difícil estabelecer vínculos claros entre as causas subjacentes e o desmatamento porque as relações causais são menos diretas do que aquelas observadas nas causas imediatas. Por exemplo, o desemprego, a pobreza, a corrupção, a má administração dos recursos governamentais e a falta de engajamento da sociedade na gestão pública podem não estar diretamente associados ao desmatamento, porém são fundamentais para compreender as suas causas e para elaborar estratégias eficazes de conservação florestal.

Adicionalmente, Bush e Gallon (2017) identificaram não apenas os fatores que impulsionam o desmatamento, mas também aqueles que contribuem para sua redução, conforme destacado no Quadro 4.

Quadro 4. Fatores associados com o aumento ou com a redução da taxa do desmatamento em florestas tropicais

Relação	Fatores associados com o desmatamento
Aumentam a taxa	Solos mais adequados para a agricultura; preços de commodities agrícolas mais altos; proximidade com: áreas cultivadas, áreas anteriormente desmatadas, cidades e rodovias; aumento da renda rural
Reduzem a taxa	Altitudes mais elevadas; encostas mais íngremes; áreas úmidas; áreas legalmente protegidas; aplicação de leis de proteção florestal; pagamentos por serviços ambientais; presença de povos indígenas

Fonte: Adaptado de Bush e Gallon (2017).

Após examinar o Quadro 4, nota-se que os fatores ligados à agricultura se sobressaem entre os demais fatores de aumento da taxa de desmatamento, especialmente em países em desenvolvimento (Hosonuma *et al.*, 2012). Nessa perspectiva, Domingues e Bermann (2012) descobriram que a intensificação das atividades agrícolas, como o cultivo de soja em pastagens já existentes (onde os custos de implementação são menores), levou à expansão da pecuária para outras regiões da Floresta Amazônica no Brasil.

A proximidade de rodovias e de áreas previamente desmatadas eleva as taxas de desmatamento, pois facilita o acesso às áreas florestais e reduz os custos associados ao desmatamento. Do mesmo modo, florestas próximas a áreas urbanas têm maior probabilidade de serem desmatadas devido à expansão urbana para uso residencial, comercial e industrial. Além disso, o aumento da renda rural pode impulsionar o desmatamento devido ao aumento da demanda por terra para atividades agrícolas, pecuárias, imobiliárias, entre outras, dependendo da região e das políticas governamentais em vigor (Bush; Gallon, 2017).

No que diz respeito aos fatores que diminuem a taxa de desmatamento, é provável que as florestas localizadas em altitudes mais elevadas, encostas mais íngremes ou áreas úmidas apresentem taxas menores de desmatamento. Isso ocorre devido a fatores legais, geográficos e climáticos específicos desses locais, além de serem menos acessíveis e oferecerem condições restritivas para atividades de cultivo (Bush; Gallon, 2017).

Além desses elementos de redução, as áreas legalmente protegidas desempenham um papel significativo na redução das taxas de desmatamento nas florestas. Segundo dados da FAO (2020), mais de 730 milhões de hectares de floresta no planeta estão abrangidos por áreas legalmente protegidas, representando 17,88% do total. Na América do Sul, essa proporção equivale a 30,48% (257,31 milhões de hectares), enquanto no Brasil atinge 30,12% (149.581,82 mil hectares). Áreas legalmente protegidas são espaços territoriais que, devido ao seu valor natural, devem ser preservadas da exploração do homem. Sua criação visa proteger a fauna e a flora ameaçadas ou potencialmente ameaçadas de extinção (Sirvinskas, 2018).

Uma pesquisa sobre áreas protegidas conduzida por Geldmann *et al.* (2019) em 152 países revelou que, embora ocorra perda de vegetação nativa, a pressão humana nas áreas florestais protegidas é menor do que nas áreas desprotegidas, o que contribui para a persistência da biodiversidade nesses locais. No Brasil, destacam-se como exemplos de áreas protegidas as Unidades de Conservação (UCs), que incluem tanto áreas de Proteção

Integral quanto de Uso Sustentável, as Áreas de Preservação Permanente (APP) e as Reservas Legais (ARL).

Além de garantir a proteção desses espaços, a Constituição da República Federativa do Brasil de 1988, por meio do artigo 231 e do artigo 68 do Ato das Disposições Constitucionais Transitórias (ADCT), também assegurou a proteção das terras indígenas e quilombolas, respectivamente (Brasil, 1988). Nesse interim, Pinto *et al.* (2022) publicaram um estudo que demonstrou o papel dos territórios indígenas e quilombolas na preservação da floresta nativa da Amazônia Brasileira. Segundo eles, os territórios indígenas e quilombolas perderam, respectivamente, 17 e 5,6 vezes menos cobertura vegetal do que áreas desprotegidas entre os anos de 2012 e 2015.

Adicionalmente, os resultados indicaram que no período de 2012 a 2017, esses locais contribuíram duas a três vezes mais para a regeneração da vegetação nativa. Assim, fica evidente que a proteção dos territórios indígenas e quilombolas contribui para a preservação da cobertura vegetal natural e na proteção da biodiversidade que habita essas regiões (Pinto *et al.*, 2022).

Além disso, medidas como pagamento por serviços ambientais, restrições ao crédito agrícola para áreas irregulares, certificação ambiental e moratórias em concessões agrícolas, que não são o cerne deste trabalho, são instrumentos de política econômica que, em conjunto com políticas públicas ambientais, desempenham um papel crucial na preservação das florestas e sua biodiversidade (Bush; Gallon, 2017).

2.9. DESMATAMENTO NO BRASIL

Embora as taxas globais de desmatamento tenham diminuído em 29% entre 2010 e 2018, em comparação com o período anterior de 2000 a 2010 (de 11 para 7,8 Mha/ano), há uma preocupação com o aumento do desmatamento nas florestas tropicais, como salientado pela FAO (2020). Esse aumento é especialmente marcante em países em desenvolvimento, como destacado por Ritchie e Roser (2021).

Nesse contexto, entre 2000 e 2018, a América do Sul teve a maior taxa de desmatamento do mundo, totalizando 68 milhões de hectares, seguida pela África com 49 milhões de hectares e a Ásia com 36 milhões de hectares (FAO, 2020). O Brasil, segundo país do mundo com maior cobertura florestal e único com extensas áreas de florestas tropicais, é um dos líderes em desmatamento (Juvenal; Mattos, 2002; BBC, 2021). Segundo

a FAO (2022), desde 1990, o Brasil tem enfrentado uma significativa perda de suas florestas, incluindo as florestas primárias.

No ano de 2022, de acordo com o Relatório Anual de Desmatamento (RAD) do Projeto MapBiomas Alerta, foram identificados um total de 76.193 alertas de desmatamento em todo o território nacional, totalizando mais de dois milhões de hectares de área desmatada. Isso equivale a mais de 90% da área total do Estado do Sergipe. É importante observar que menos de 2% dos alertas de desmatamento identificados têm permissão legal para suprimir a vegetação nativa, sugerindo que mais de 98% dos desmatamentos ocorridos no Brasil possuem indícios de ilegalidade (RAD, 2022).

Além disso, em comparação com o ano de 2021, houve um aumento de 22,3% das áreas desmatadas e de 24,2% na velocidade de desmatamento no país, passando de 4.536 hectares por dia para 5.636,3 hectares por dia (RAD, 2022). A essa velocidade, o equivalente ao território do município de Feira de Santana, na Bahia, seria totalmente desmatado em menos de 25 dias. Esse aumento indica uma aceleração preocupante do processo de desmatamento no Brasil, destacando a urgência de medidas eficazes de conservação e proteção ambiental.

De acordo com o RAD (2022), a agropecuária, o garimpo, a mineração e a expansão urbana foram identificados como os principais vetores de desmatamento no país. Arraes, Mariano e Simonassi (2012) acrescentaram a malha rodoviária. Ramos *et al.* (2019) identificaram as queimadas como causas indiretas do desmatamento. No bioma Mata Atlântica (Figura 5), a Fundação SOS Mata Atlântica (2021), apontou a exploração de madeira, as atividades agropastoris, a industrialização e a expansão da zona urbana como os principais vetores de desmatamento na região.

2.10. DESMATAMENTO NO BIOMA MATA ATLÂNTICA

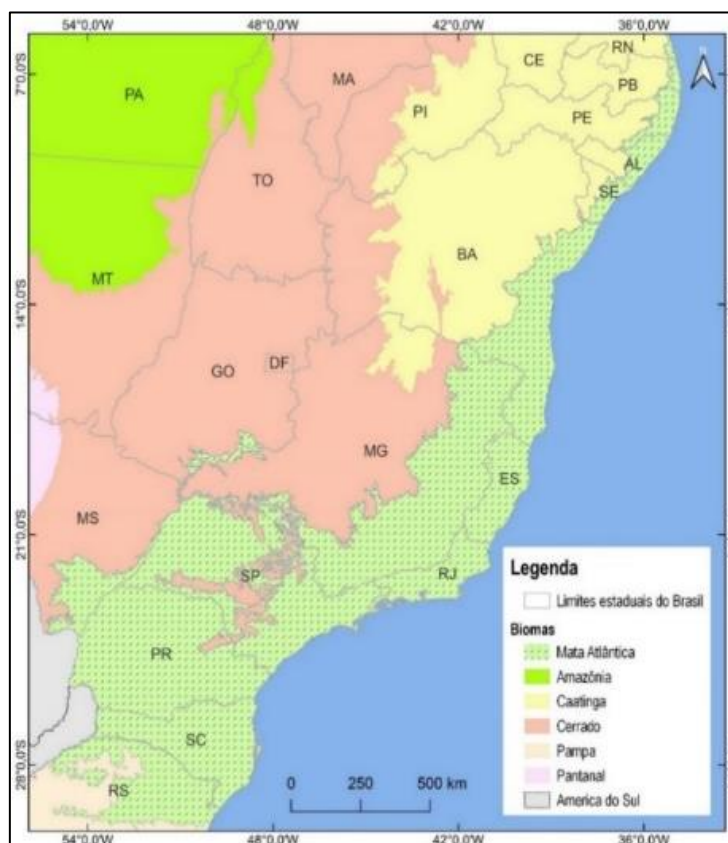
Segundo Coutinho (2016), um bioma é um espaço geográfico natural que ocorre em grandes áreas, caracterizado pela uniformidade: do clima, de condições edáficas (referente a propriedades físicas e químicas do solo) e de fitofisionomia. Entretanto, como aponta o autor, a Mata Atlântica, assim como a Amazônia, não se enquadra bem no conceito de bioma, pois é composta por um conjunto de diferentes solos, climas e vegetações (Coutinho, 2016).

A Mata Atlântica está localizada na região costeira do Brasil e é delimitada pelo Oceano Atlântico a leste, pelos biomas Caatinga e Cerrado a oeste e pelo Pampa ao Sul,

(Figura 5). Segundo a Fundação SOS Mata Atlântica (2021), mais de 72% da população brasileira reside neste bioma, onde são também encontradas sete das nove maiores bacias hidrográficas do país e três dos maiores centros urbanos do continente sul-americano.

A Mata Atlântica é um bioma extremamente diversificado devido à sua localização geográfica e processo evolutivo. É o lar de numerosas espécies endêmicas, incluindo mamíferos, aves, répteis e anfíbios. Além disso, a diversidade arbórea está entre as mais altas do mundo, com 454 espécies de árvores encontradas em um único hectare de floresta no Estado da Bahia. Por isso, o bioma Mata Atlântica é considerado um dos cinco maiores *hotspots* de biodiversidade do Planeta (Leal; Câmara, 2005; Mittermeier; Fonseca, 2021), além de ser considerado Patrimônio Nacional pela Constituição Federal/1988.

Figura 5. Localização geográfica e abrangência territorial do bioma Mata Atlântica



Fonte: Próprio autor, 2022

Segundo Rosa (2021), a Mata Atlântica ocupa 13% do País e é considerada um dos biomas mais ameaçados, com a menor cobertura original de floresta entre todos os biomas brasileiros. No livro “A Ferro e Fogo: a história e a devastação da Mata Atlântica brasileira”, Dean (1996) detalha o histórico de desmatamento da Mata Atlântica em ciclos de uso da

terra, destacando como diferentes atividades econômicas ao longo dos séculos contribuíram para a devastação desse bioma.

Entre esses ciclos, destacam-se: a Exploração do Pau-Brasil (Século XVI), a Agricultura de Cana-de-Açúcar (Séculos XVI e XVII), a Exploração do Ouro (Século XVIII), a Agricultura do Café (Século XIX) e a Industrialização e Urbanização (Século XX). De acordo com Solórzano, Brasil e Oliveira (2021), esses ciclos resultaram na perda de mais de 70% da cobertura original da Mata Atlântica. Atualmente, restam apenas fragmentos florestais isolados, que variam em idade e grau de degradação.

Os remanescentes florestais da Mata Atlântica desempenham um papel crucial na conservação da biodiversidade e na manutenção de serviços ecossistêmicos essenciais (Rosa, 2021), especialmente considerando que 72% da população brasileira reside nesse bioma. Portanto, é fundamental monitorar e fiscalizar constantemente essa região, além de implementar políticas públicas ambientais voltadas para a proteção desse bioma (como a aprovação da Lei nº 11.428/2006 que dispõe sobre a utilização e proteção da vegetação nativa do Bioma Mata Atlântica). Entre as iniciativas de monitoramento dos fragmentos florestais da Mata Atlântica, destacam-se os trabalhos desenvolvidos pela Fundação SOS Mata Atlântica, pelo Instituto Nacional de Pesquisas Espaciais (INPE) e pelo MapBiomas.

O primeiro mapeamento deste bioma foi concluído em 1990 pela Fundação SOS Mata Atlântica e pelo INPE, permitindo identificar e mapear os remanescentes florestais em todo o bioma e contribuindo para a definição dos limites originais da Mata Atlântica, utilizando uma escala de 1:1.000.000 e uma área mínima mapeada de 40 hectares. Desde então, o processo de mapeamento tem evoluído, resultando em publicações anuais com escalas maiores e resoluções de imagem aprimoradas, detalhando mais feições e possibilitando um monitoramento dos desmatamentos mais eficaz (Rosa, 2021).

De acordo com o Relatório Anual de Desmatamento (RAD, 2022) do projeto MapBiomas Alerta, o bioma Mata Atlântica registrou um aumento de 53,7% nos alertas de desmatamento no ano 2021 em relação ao ano anterior. Segundo a Fundação SOS Mata Atlântica (2023), entre 2021 e 2022, aproximadamente 20.075 hectares de mata nativa foram desmatados na área de abrangência da Lei da Mata Atlântica. Os estados de Minas Gerais, Bahia, Paraná, Mato Grosso do Sul e Santa Catarina foram responsáveis por 91% desse desmatamento. Ademais, foi constatado que 73% dessa área desmatada ocorreu em propriedades privadas (SOS Mata Atlântica, 2023).

No Estado da Bahia, apenas 11,0 % de sua área é composta por remanescentes florestais de Mata Atlântica, totalizando 1.981.540 hectares. Dentre esse montante, 5.719

hectares foram desmatados entre 2021 e 2022, marcando um aumento de 15% em relação ao período anterior (2020-2021). Esse cenário coloca a Bahia como o estado que mais reduziu os remanescentes de Mata Atlântica na região Nordeste e o segundo no país, atrás apenas de Minas Gerais (SOS Mata Atlântica, 2023).

Com base no que foi apresentado, fica claro que a biodiversidade de espécies no bioma Mata Atlântica, especialmente na região do Estado da Bahia, enfrenta uma grave ameaça de extinção. A preservação e conservação dessa diversidade são fundamentais para manter o equilíbrio no bioma Mata Atlântica e garantir a continuidade dos serviços ecossistêmicos essenciais para os seres humanos e para a economia.

Assim como o artigo 144 da Constituição Federal/1988 enfatiza que a segurança pública é uma responsabilidade do Estado, o artigo 225 da mesma legislação estabelece um compromisso semelhante. Dentro desse contexto, o Estado tem a obrigação de assegurar o direito a um meio ambiente ecologicamente equilibrado para as atuais e futuras gerações.

Conforme apontado por Sirvinskas (2018), o direito ao meio ambiente ecologicamente equilibrado é reconhecido como fundamental, pois está intrinsecamente relacionado ao direito à vida, sendo indissociável deste. Assim, a preservação ambiental deve ser reconhecida como parte das responsabilidades das polícias militares, uma vez que a degradação ambiental compromete a ordem pública.

Diante do que foi descrito, o desenvolvimento de estudos que considerem os fatores de risco causadores do desmatamento, com foco na previsão de áreas propensas ao desflorestamento, principalmente o criminoso, são ferramentas importantes para a elaboração de planos estratégicos ou operacionais de combate ao desmatamento.

3. QUESTÃO NORTEADORA

Os princípios da criminologia ambiental, aplicados por meio da modelagem RTM, serão capazes de identificar *hotspots* de desmatamento ilegal no município de Canavieiras/Bahia?

4. OBJETIVOS

4.1. OBJETIVO GERAL

Analisar a aplicabilidade da modelagem RTM para identificar *hotspots* de desmatamento ilegal no município de Canavieiras/BA, como uma estratégia de policiamento preditivo, visando implementar ações preventivas de policiamento ostensivo para reduzir as taxas de desmatamento na região.

4.2. OBJETIVOS ESPECÍFICOS

- Apresentar a modelagem RTM;
- Apresentar os fatores de risco associados ao desmatamento de florestas tropicais, conforme estudos de Geist e Lambin (2001);
- Elaborar mapas de *hotspots* de desmatamento no município de Canavieiras/Bahia, utilizando a metodologia RTM;
- Analisar as potencialidades da modelagem RTM na implementação de ações preventivas de policiamento ostensivo para reduzir as taxas de desmatamento na região.

5. METODOLOGIA

Nesta seção, são descritos os procedimentos adotados para o desenvolvimento desta pesquisa, incluindo a caracterização da área de estudo, a identificação dos fatores de risco de desmatamento e o método de aplicação da modelagem RTM utilizado neste estudo. Também são abordadas as estratégias implementadas para alcançar os objetivos da pesquisa. Ressalta-se que este trabalho seguiu uma abordagem semelhante à proposta por Limeira (2022).

A escolha de Canavieiras como área de estudo destaca-se por sua localização integral na Mata Atlântica, um bioma reconhecido como um *hotspot* de biodiversidade e altamente vulnerável às atividades humanas, tornando-a uma área prioritária para conservação. Salienta-se que a região apresenta uma diversidade significativa de coberturas do solo (Figura 7), além de um litoral extenso (Figura 6), que abriga

ecossistemas costeiros sensíveis, como manguezais e restingas, essenciais para a manutenção da biodiversidade.

Essas características conferem a área de estudo um valor ecológico estratégico, tanto para a conservação da flora e fauna quanto para a segurança ambiental das populações locais, que dependem diretamente dos serviços ecossistêmicos fornecidos pela natureza. Além disso, a crescente pressão da expansão agrícola sobre os fragmentos florestais remanescentes também foi um fator relevante na seleção da área. Segundo o MapBiomias (2022), Canavieiras está entre os municípios, situados no Estado da Bahia, que registraram os maiores índices de desmatamento no bioma Mata Atlântica.

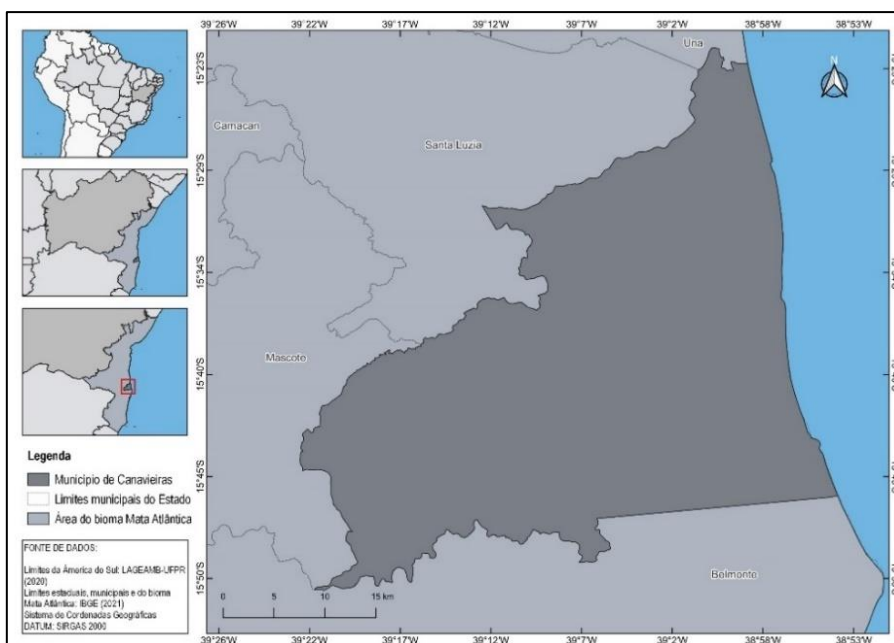
Sabe-se que a contínua fragmentação das áreas florestais impacta a biodiversidade, elevando o risco de extinção de espécies locais, além de comprometer serviços ecossistêmicos fundamentais para a sociedade. Esses aspectos exigem uma atenção especial das autoridades públicas responsáveis pela fiscalização e proteção ambiental, bem como de toda a sociedade civil.

Frente a esse cenário, a escolha do município de Canavieiras como área de estudo é justificada pela necessidade urgente de mitigar os impactos ambientais e sociais decorrentes do desmatamento na região, promovendo a gestão sustentável dos recursos naturais, garantindo a preservação da biodiversidade local e a continuidade do fornecimento de serviços ecossistêmicos essenciais para a sociedade canavieirense.

5.1. CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A área de pesquisa abrange as formações florestais localizadas no município de Canavieiras, situado no litoral da região Sul do Estado da Bahia, delimitado pelas coordenadas geográficas de 15° 23' a 15° 57' S e 38° 53' a 39° 25' W, na região conhecida como Costa do Descobrimento. Canavieiras está completamente inserida no bioma da Mata Atlântica e faz fronteira com os municípios baianos de Mascote, Una, Belmonte e Santa Luzia, como ilustrado na Figura 6.

De acordo com o IBGE (2022), Canavieiras possui uma área de aproximadamente 1.334,284 km² e uma população de 32.683 habitantes, sendo que 80,11% residem na zona urbana e 19,89% na zona rural. Entre as principais atividades econômicas desenvolvidas destacam-se: pesca marinha e estuarina, agricultura familiar, pecuária, além da silvicultura e o turismo (Nascimento; Dominguez, 2009; Cardozo *et al.* 2019).

Figura 6. Mapa de localização do município de Canavieiras/BA

Fonte: Próprio autor, 2022

Quanto à configuração do relevo, Canavieiras é caracterizada por planícies, tabuleiros e serras (Nascimento; Dominguez, 2009). Em relação a topografia deste município, adotou-se a classificação proposta pela EMBRAPA (1999), conforme apresentado na Tabela 1.

Tabela 1. Inclinação do território do município de Canavieiras/BA, segundo classificação da EMBRAPA (1999)

Declividade	Área (km ²)	%
Suave Ondulado (3 – 8%)	522,96	39,19
Ondulado (8 – 20%)	346,31	25,95
Plano (0 – 3%)	319,08	23,91
Forte Ondulado (20 – 45%)	144,00	10,79
Montanhoso (45 – 75%)	1,93	0,14
TOTAL	1.334,28	100,00

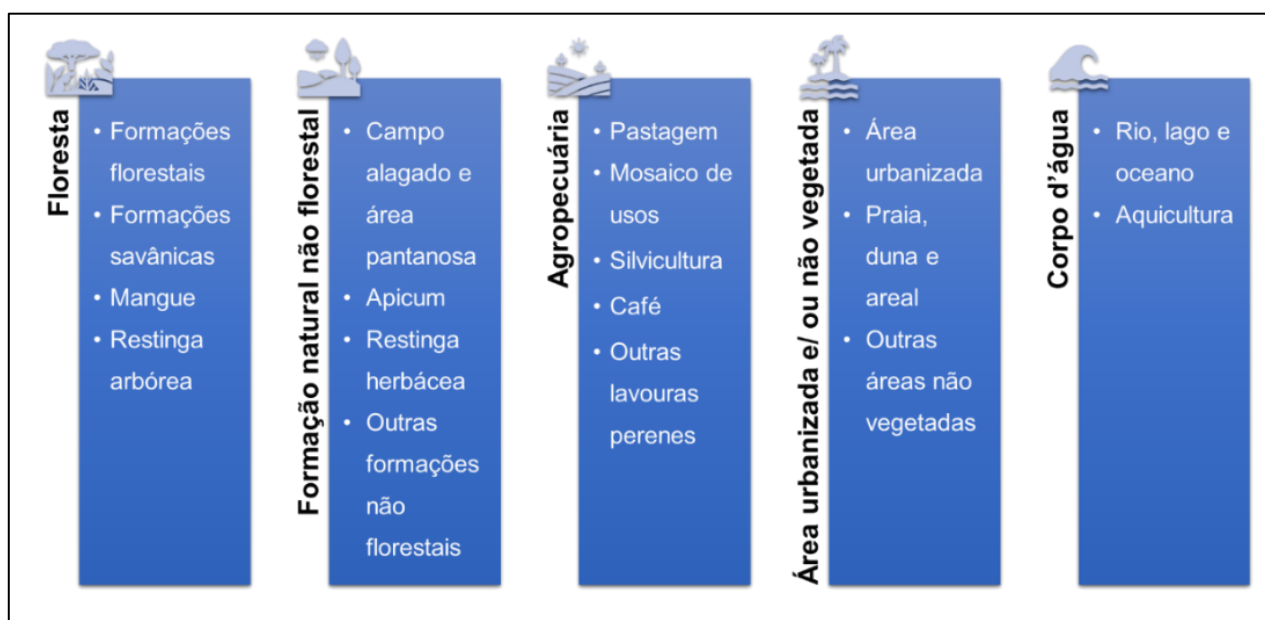
Fonte: Adaptado SRTM, 2022

Da análise da Tabela 1, destaca-se que a maior parte do território do município de Canavieiras compreende áreas suavemente onduladas e onduladas (65,14%), seguidas de áreas planas (23,91%), e uma porção menor em terreno montanhoso (0,14%). Quanto ao clima, Canavieiras está localizada em uma região classificada como úmida e úmida a

subúmida, conforme a categorização de Thornthwaite e Matther (1955) *apud* Superintendência de Estudos Econômicos e Sociais da Bahia (1998).

Quanto aos tipos de uso e cobertura da terra, Canavieiras é composta por formações florestais e savânicas, manguezais, restingas arbóreas, campos alagados, apicuns, pastagens, áreas urbanizadas, entre outras, segundo classificação do MapBiomias (2022). Contudo, neste estudo, optou-se em agrupá-los em categorias de Nível 1, conforme metodologia proposta pelo MapBiomias (2022), com o objetivo de simplificar a representação visual da área, como demonstrado na Figura 7.

Figura 7. Classificação em categorias de Nível 1 dos tipos de uso e cobertura do solo identificados em Canavieiras/BA em 2022

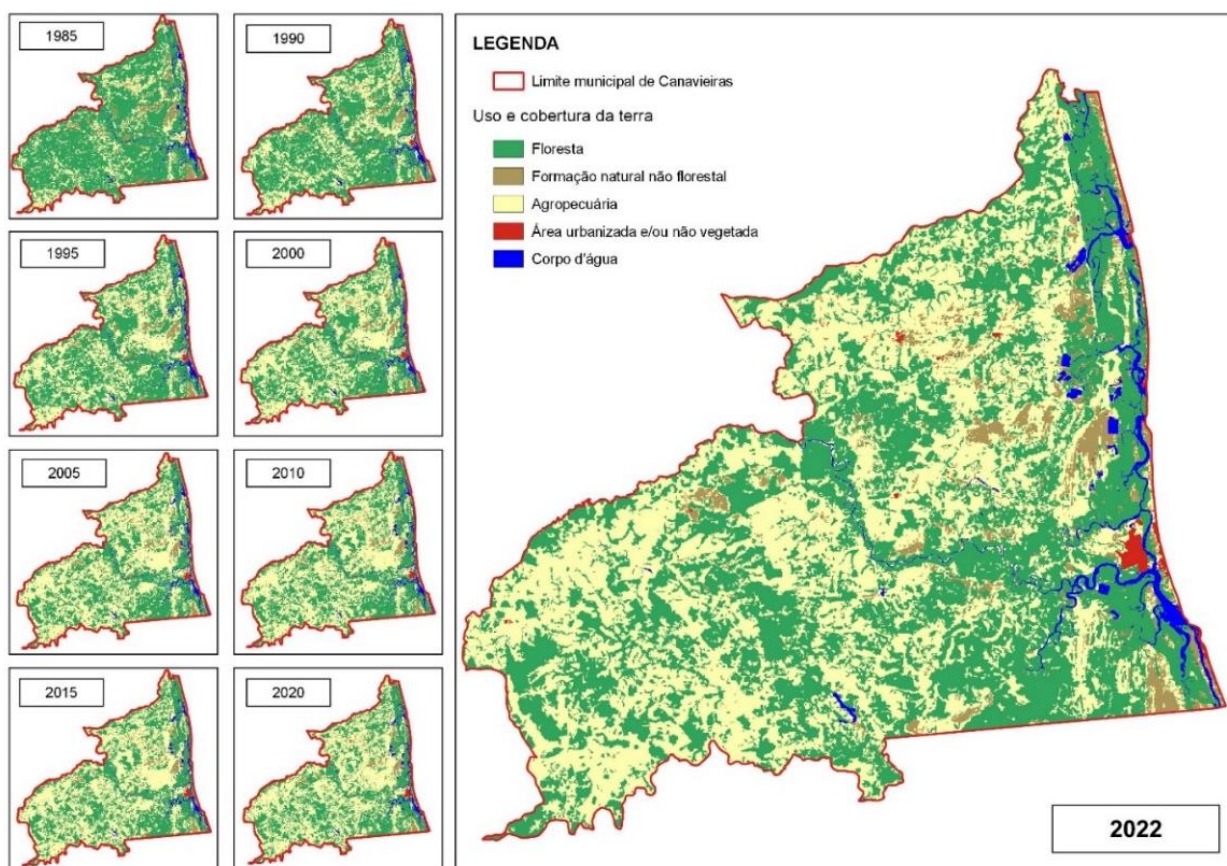


Fonte: Adaptado MapBiomias, 2022

Ao reclassificar as categorias de uso e cobertura do solo, conforme esquema ilustrado na Figura 7, foi elaborado o mapa de uso e cobertura do solo de Canavieiras, resultando na área representada na Figura 8.

Ao observar a Figura 8, verifica-se que a área florestal em Canavieiras é altamente fragmentada, refletindo um padrão comum de regiões situadas no bioma Mata Atlântica. Segundo informações extraídas do MapBiomias (2022), Canavieiras abriga atualmente 1.956 fragmentos florestais, cujas áreas oscilam entre 0,09 e 19.077,94 hectares, com uma média de 31,64 hectares.

Figura 8. Processo de uso e ocupação do solo no município de Canavieiras/BA de 1985 a 2022



Fonte: MapBiomas, 2022

5.2. DETERMINAÇÃO DOS FATORES DE RISCO DE DESMATAMENTO

Fatores de risco são variáveis que influenciam no aumento ou na redução do risco de ocorrência de um evento (Silva, 2017). Para identificar esses fatores, foram considerados os exemplos de causas diretas de desmatamento em florestas tropicais apontados por Geist e Lambin (2001), além de pesquisas em outras fontes literárias relevantes sobre o assunto. O Quadro 5 apresenta uma lista dos fatores de risco utilizados neste estudo.

Além dos exemplos listados no Quadro 5, este estudo propôs acrescentar outros fatores de risco que aumentam a taxa de desmatamento como a presença de assentamentos rurais (Farias *et al.*, 2018), de silvicultura (Santos *et al.*, 2020) e de áreas previamente desmatadas (Bush; Gallon, 2017).

Quadro 5. Fatores de risco que influenciam no desmatamento de florestas tropicais segundo Geist e Lambin (2001)

Fatores de risco que aumentam a taxa de desmatamento
Presença de cicatrizes de queimada
Presença de estradas ou rodovias
Presença de pastagem, agricultura e zonas urbanas
Presença de áreas planas

Fonte: Adaptado de Geist e Lambin (2001).

Optou-se também por incorporar o Cadastro Ambiental Rural (CAR) como um fator de risco adicional que contribui para o aumento do desmatamento. Observou-se que 80,1% dos alertas de desmatamento em Canavieiras estavam localizados nessas áreas, tornando o CAR um indicador significativo de maior susceptibilidade ao desmatamento em Canavieiras. Isso indica que a maioria dos alertas de desmatamento está em áreas privadas.

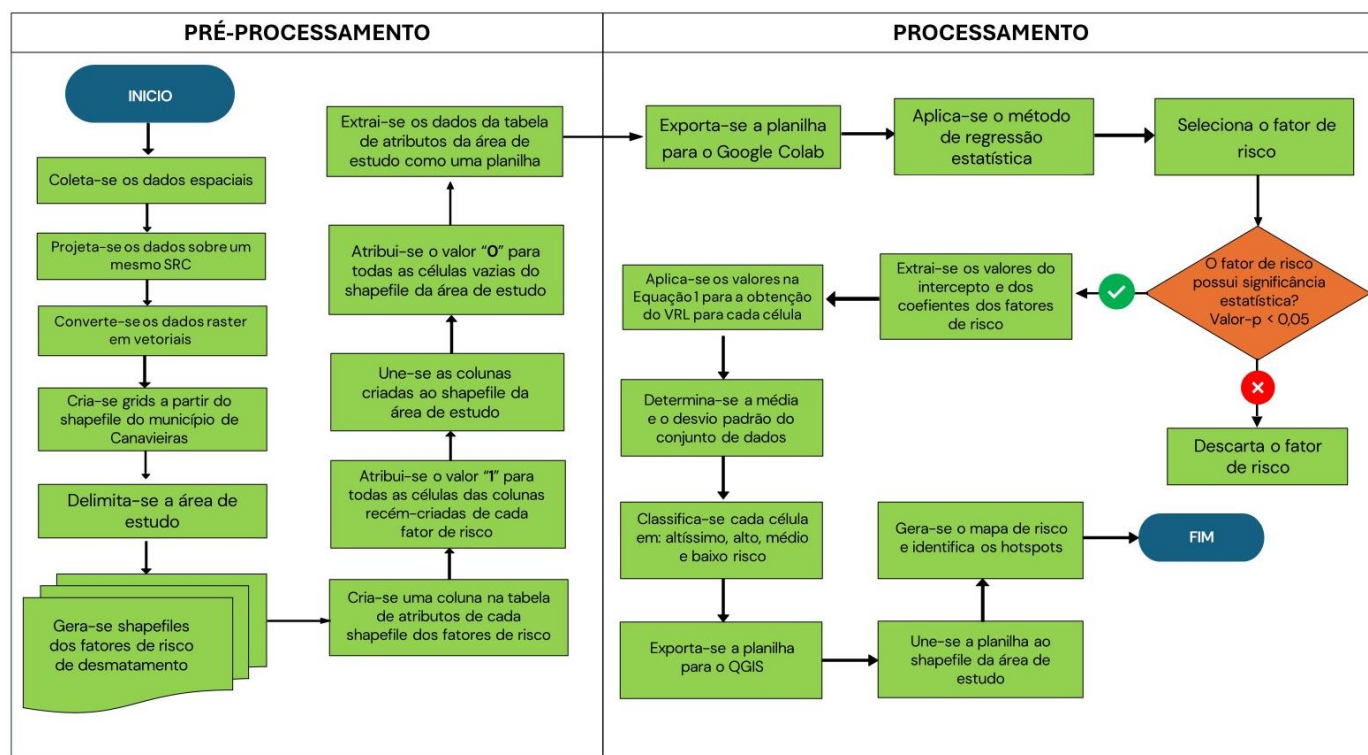
Além disso, considerou-se como um fator de risco adicional para o aumento do desmatamento a categoria de uso e cobertura Mosaico de Usos, um subtipo da atividade agropecuária, que também está associado à ocorrência de desmatamento. É importante salientar que todos os dados utilizados são de domínio público e estão acessíveis na internet.

Ademais, acrescentou-se na listagem de fatores de risco que reduzem a ocorrência de desmatamento a presença de Áreas de Preservação Permanente (APP) e de Reserva Legal (RL), segundo Pacheco e Meyer (2022). Embora tenham sido mencionados neste estudo, os territórios indígenas e quilombolas não foram contemplados, pois não foram identificados na área de pesquisa. O Quadro 8, localizado no Apêndice I, apresenta uma relação detalhada de todos os dados empregados neste estudo, incluindo seu tipo e fonte.

5.1. APLICAÇÃO DA MODELAGEM RTM

Para a aplicação da modelagem RTM, de acordo com os objetivos deste estudo, o processo foi dividido em duas etapas: pré-processamento e processamento dos dados, como ilustrado no fluxograma apresentado na Figura 9.

Figura 9. Fluxograma adotado para a modelagem RTM



Fonte: Próprio autor, 2022

No pré-processamento, foram realizadas atividades de coleta, organização e tratamento dos dados, assegurando a consistência e qualidade da base de informações. No processamento, foram aplicadas as técnicas de análise estatística para identificar e analisar os fatores de risco de desmatamento. Essas etapas são fundamentais para garantir resultados precisos e coerentes com os objetivos do estudo

Adicionalmente, destaca-se que o período de análise está compreendido entre 2019 e 2022, com horizonte de previsão de um ano. Ou seja, os dados do ano anterior foram empregados para projetar as informações do ano seguinte (dados de 2019 para prever 2020, por exemplo), com o objetivo de avaliar a capacidade preditiva da modelagem RTM na previsão de desmatamentos ilegais.


5.1.1. PRÉ-PROCESSAMENTO

Para o pré-processamento dos dados, empregou-se o *software* QGIS na versão 3.22.4-*Białowieża*. Para garantir a consistência, é essencial que todos os dados estejam projetados no mesmo Sistema de Referência de Coordenada (SRC). Portanto, neste estudo, os dados listados no Quadro 8 foram reprojetoados para o SRC Sirgas 2000/UTM

zona 24S (código EPSG 31984). É importante destacar que os dados *raster* devem ser convertidos para formato vetorial. A partir desse ponto deve-se:

- a) gerar um *shapefile* composto por *grids*¹ hexagonais² (Figura 10) com base no arquivo *shapefile* do município de Canaveiras, utilizando uma dimensão de 100 x 100 metros³;

Figura 10. Divisão do território de Canaveiras/BA em grids hexagonais



Fonte: Próprio autor (2022)

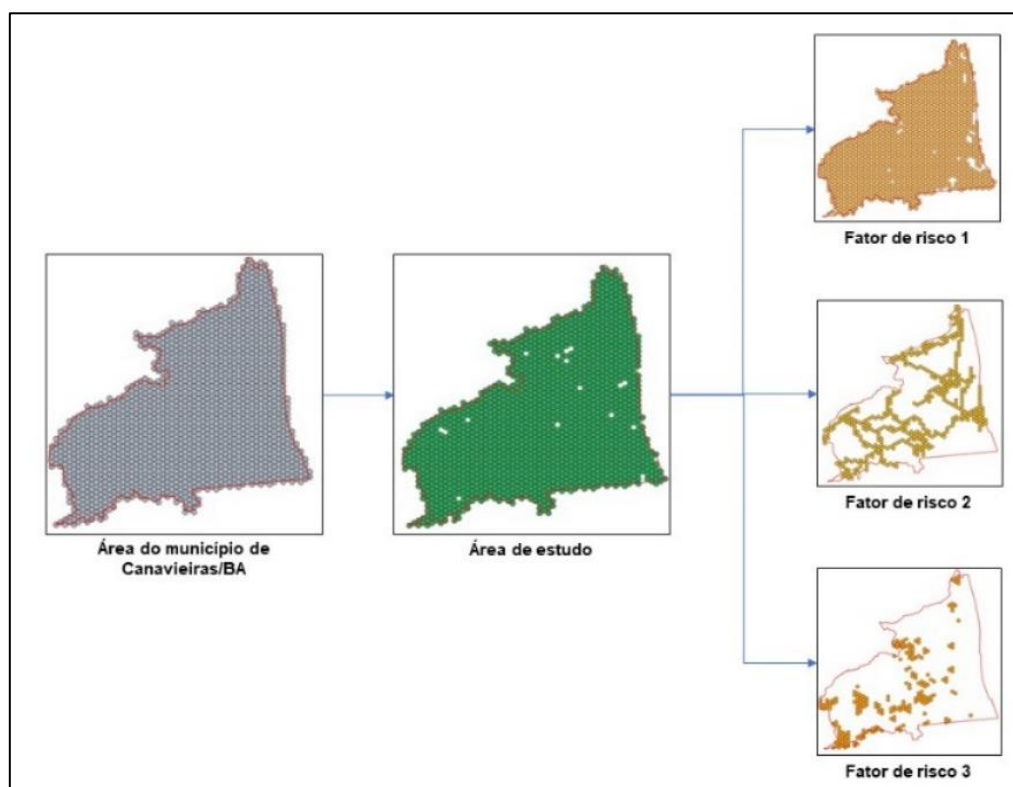
- b) delimitar a área de estudo, selecionando-se *grids* que contenham fragmentos florestais. Isso se justifica devido ao fato de que o município de Canaveiras não é totalmente coberto por florestas, como demonstrado na Figura 8;
- c) gerar novos *shapefiles* de *grids* hexagonais que representem os fatores de risco de desmatamento, mediante a interseção de cada fator de risco listado no Quadro 8 com o *shapefile* da área de estudo criado na etapa b), como ilustrado na Figura 11;

¹ Grids são divisões regulares de uma área em pequenas células ou quadrículas usadas para organizar, mapear e analisar dados espaciais, facilitando o estudo de padrões geográficos ao permitir a análise detalhada de cada célula do território;

² Foi utilizada a forma hexagonal do *grid* para evitar o surgimento de efeitos de borda;

³ Testaram-se tamanhos de *grid* variando de 1 x 1 km até 300 x 300 metros, mas o tamanho inicial apresentou os melhores resultados, também levando em conta a capacidade de processamento do computador usado;

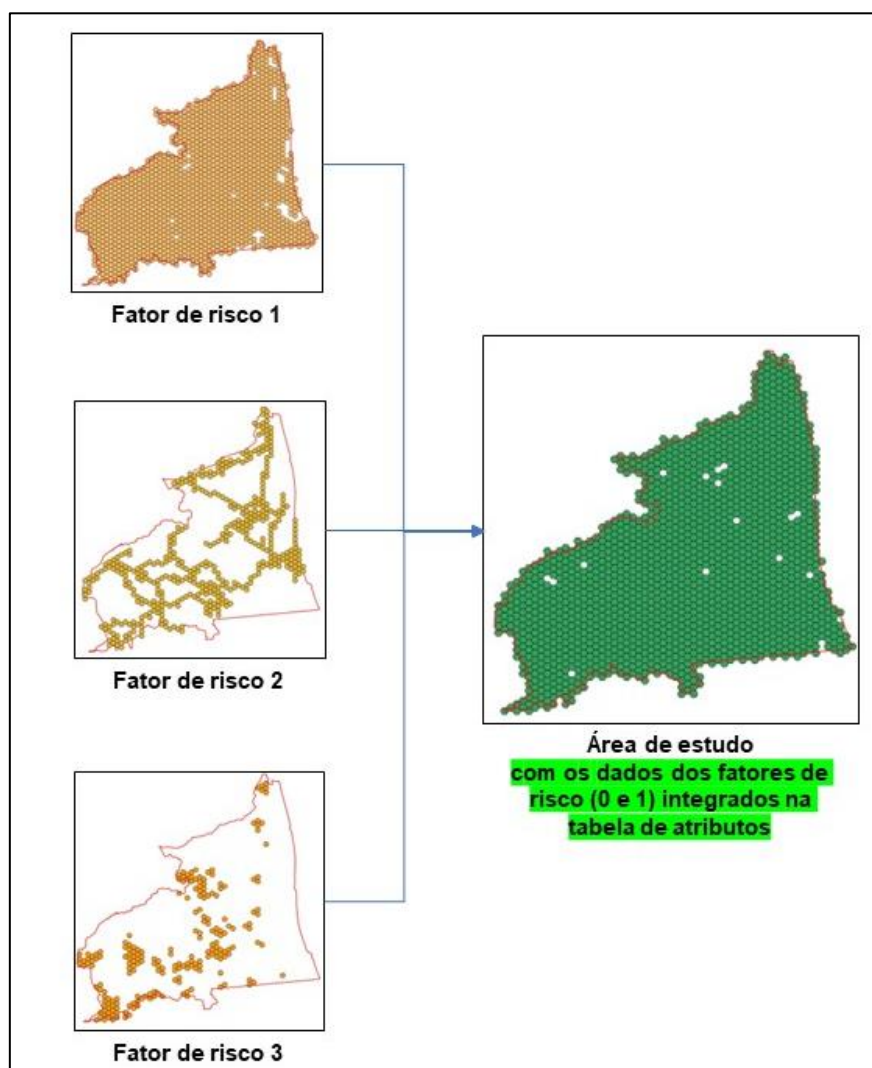
Figura 11. Delimitação da área de estudo e geração de camadas shapefile dos fatores de risco



Fonte: Próprio autor (2022)

- d) criar uma coluna na tabela de atributos de cada *shapefile* de *grids* hexagonais criado na etapa c), atribuindo a cada célula o valor "1". Esse valor indica a presença do fator de risco na célula do *grid* da área de estudo;
- e) unir as colunas criadas na etapa d) ao *shapefile* da área de estudo criada na etapa b). Este procedimento é parcialmente ilustrado na Figura 12;
- f) atribuir o valor "0" às células vazias da tabela de atributos do *shapefile* da área de estudo, que já contém as informações descritas na letra d) deste passo-a-passo. O valor "0" representa a ausência do fator de risco na célula do *grid* da área de estudo. Essa etapa é essencial para gerar uma planilha composta por dados binários (0 e 1), que indicam a ausência ou presença, respectivamente, do fator de risco no *grid* da área de estudo, sendo indispensável para realizar o diagnóstico dos fatores de risco, previamente identificados, na etapa de processamento com o intuito de aplicar a modelagem RTM.

Figura 12. Processo de integração das camadas dos fatores de risco ao shapefile da área de estudo



Fonte: Próprio autor (2022).

Antes de dar continuidade com os demais passos é necessário esclarecer que a influência dos fatores de risco utilizadas neste trabalho foi operacionalizada com base na sua presença na célula do *grid*. Assim, presença de fatores de risco na célula do *grid* aumenta a probabilidade de desmatamento, enquanto sua ausência a diminui.

Portanto, quanto mais fatores de risco estiverem presentes em uma célula do *grid*, maior será o risco de desmatamento nessa área. Regiões com alta concentração de fatores de risco serão classificadas como *hotspots* de desmatamento, sendo destacadas com cores de tonalidade mais intensa. Quanto maior o número de fatores em uma célula do *grid*, mais vibrante será a cor exibida no mapa.

Adicionalmente, no que diz respeito aos fatores que diminuem o risco, como APP e RL, foi adotada a seguinte estratégia: áreas situadas fora de seus limites foram

consideradas mais propensas ao desmatamento, recebendo o valor "1", enquanto as regiões dentro desses espaços de proteção ambiental foram designadas com o valor "0", indicando uma menor propensão ao desmatamento. Essa abordagem permite diferenciar claramente as zonas de proteção ambiental das áreas vulneráveis, auxiliando na identificação de *hotspots* com maior precisão.

5.1.2. PROCESSAMENTO DOS DADOS

Durante esta etapa, foram empregados o *software MS Excel* e a plataforma *Colab* do *Google*. O *Google Colab*, também conhecido como *Google Colaboratory*, é uma plataforma em nuvem gratuita fornecida pelo *Google* que possibilita aos usuários escreverem e executarem código *Python* em um ambiente na nuvem sem a necessidade de configurações ou instalações em seus próprios computadores.

Nesta fase, é feito o diagnóstico dos fatores de risco pré-selecionados, conforme levantamentos bibliográficos, para a escolha daqueles serão aplicados modelagem RTM. Somente aqueles fatores que sejam estatisticamente significativos, em relação ao objeto de estudo, serão utilizados.

A planilha gerada a partir do mapa vetorial composto, resultante da união dos mapas de cada fator de risco (Figura 12) da etapa de pré-processamento, foi exportada para a plataforma *Google Colab* para a realização da análise de regressão estatística. O objetivo dessa análise foi selecionar os fatores de risco com significância estatística em relação à ocorrência de desmatamento. O diagnóstico foi conduzido utilizando as três abordagens de regressão previamente mencionadas neste estudo: binomial negativa, Poisson e binomial.

A análise de regressão no RTM representa uma etapa crucial da modelagem, visando determinar quais fatores de risco devem ser incorporados ao modelo com base nos valores-p associados a esses fatores. Um valor-p inferior a 0,05 indica que o fator provavelmente contribui para o modelo, demonstrando significância estatística. Por outro lado, se o valor-p do fator de risco for superior a 0,05, ele é descartado por falta de correlação com o evento (Limeira, 2022).

Para realizar essa análise, foram empregados os pacotes *scipy.stats*, *statsmodels.formula.api* e *statsmodels.api* e as bibliotecas *numpy* e *pandas*, em *Python*. A metodologia de análise dos fatores de risco utilizada neste trabalho no *Google Colab* está detalhada no Apêndice VI. O Quadro 6 apresenta cada um dos pacotes e das bibliotecas utilizadas.

Quadro 6. Descrição dos pacotes e bibliotecas utilizadas na análise dos dados neste estudo

Pacote/Biblioteca	Descrição
scipy.stats	pacote que oferece uma ampla gama de funções estatísticas para análise descritiva e inferencial, como cálculo de medidas de tendência central e dispersão e realização de testes de hipóteses para verificar a significância estatística de relações entre variáveis
statsmodels.formula.api	pacote que facilita a criação e o ajuste de modelos estatísticos lineares e não lineares utilizando uma sintaxe similar à do R, como definição de modelos lineares e não lineares utilizando fórmulas matemáticas ajuste de modelos aos dados e obtenção de resultados como coeficientes de regressão e valores p
statsmodels.api	pacote que oferece uma interface mais tradicional para a criação e análise de modelos estatísticos, utilizando arrays NumPy, como a implementação de modelos estatísticos, como regressão linear, regressão logística e a realização de testes de hipóteses e análise de significância
Numpy	biblioteca fundamental para manipulação eficiente de dados em arrays multidimensionais, facilitando cálculos matemáticos e estatísticos
Pandas	biblioteca que oferece estruturas de dados eficientes para trabalhar com séries temporais e data frames, facilitando a análise e o pré-processamento de dados

Fonte: Google Colab, 2024

Durante a análise das técnicas de regressão, constatou-se que a regressão binomial alcançou os melhores resultados com base nos critérios de informação de *Akaike* (AIC) e *Bayesiano* (BIC) para os anos de 2019 a 2022. Tanto o AIC quanto o BIC são utilizados para comparar modelos estatísticos, selecionando aquele que melhor se adapta aos dados. Em ambas as abordagens, o modelo com o menor valor de AIC (ou BIC) é considerado o mais apropriado (Emiliano, 2009). O Apêndice III apresenta os resultados do modelo de regressão binomial para os anos de 2019 a 2022

Com base nos resultados obtidos, os coeficientes dos fatores de risco estatisticamente significativos, juntamente com o valor do intercepto para cada ano (Tabela 8), são extraídos e utilizados na Equação 2 para calcular o Valor do Risco Local (VRL) de cada célula no grid do mapa. Em seguida, cada célula é classificada de acordo com os critérios detalhados no Quadro 7. Para isso, é necessário primeiro calcular o valor médio e o desvio padrão do conjunto de dados de VRL.

Quadro 7. Classificação dos valores de risco local (VRL) segundo Limeira (2022)

Classificação	Parâmetro
Baixo risco	$VRL < Média$
Médio risco	$Média \leq VRL < (Média + Desvio Padrão)$
Alto risco	$(Média + Desvio Padrão) \leq VRL < (Média + 2 Desvio Padrão)$
Altíssimo risco	$VRL \geq (Média + 2 Desvio Padrão)$

Fonte: Limeira (2022)

Após essa etapa, a planilha com os resultados é exportada para o QGIS e integrada ao *shapefile* da área de estudo. Com a combinação desses dados, é gerado o mapa de risco, que permite a visualização das áreas com diferentes níveis de risco de desmatamento. Os *hotspots* de desmatamento, identificados com base na classificação de risco como alto ou altíssimo, são destacados no mapa.

A próxima seção apresenta os resultados obtidos pelos procedimentos utilizados, juntamente com a discussão desses resultados.

6. RESULTADOS

6.1. CARACTERIZAÇÃO DO USO E COBERTURA DO SOLO EM CANAVIEIRAS

A Tabela 2 mostra a área e o percentual de cada tipo de uso e cobertura do solo em Canavieiras para o ano de 2022, detalhando diferentes categorias como áreas agrícolas, florestas, pastagens, e áreas urbanas, fornecendo uma visão abrangente da distribuição do uso do solo na região.

Tabela 2. Relação da área ocupada por cada categoria de uso e cobertura da terra no município de Canavieiras/BA em 2022

Categoria principal	Tipo de uso e cobertura	Área (km²)	%
Floresta	Formação Florestal	520,24	38,989
	Mangue	71,00	5,321
	Restinga Arbórea	27,35	2,050
	Formação Savânica	0,02	0,001
Formação natural não florestal	Campo Alagado e Área Pantanosa	39,30	2,945
	Restinga Herbácea	24,70	1,851
	Outras Formações não Florestais	0,56	0,042
	Apicum	0,28	0,021
Agropecuária	Pastagem	383,54	28,745
	Mosaico de Usos	213,40	15,994
	Silvicultura	15,19	1,138
	Café	0,71	0,053
	Outras Lavouras Perenes	0,05	0,004
Área urbanizada e ou não vegetada	Área Urbanizada	4,56	0,342
	Outras Áreas não vegetadas	2,50	0,187
	Praia, Duna e Areal	1,07	0,081
Corpo d'água	Rio, Lago e Oceano	26,69	2,000
	Aquicultura	3,16	0,236
Total		1.334,32	100,00

Fonte: MapBiomas, 2022

Com base na Tabela 2, é evidente a predominância das formações florestais e das atividades agropecuárias na ocupação do solo. Os dados mostram que 46,36% do território de Canavieiras é coberto por florestas, enquanto 45,93% são destinados à agropecuária, com uma diferença de menos de 1%. Isso destaca a pressão significativa que a agropecuária exerce sobre as florestas da região. Esse cenário pode ter importantes implicações para a conservação da biodiversidade e a manutenção dos serviços ecossistêmicos locais.

A predominância de atividades agropecuárias em Canavieiras é claramente evidenciada ao analisar a Figura 9, destacando sua importância na modelagem da paisagem local. É fundamental ressaltar que as atividades agropecuárias podem acarretar impactos significativos sobre a biota local, como a fragmentação de habitats naturais, representando uma ameaça direta à biodiversidade da região. Outro fato ilustrado na Figura 9 é o processo histórico de uso e ocupação da terra em Canavieiras de 1985 a 2022.

Percebe-se que a área previamente coberta por florestas desde o ano de 1985 foi predominantemente substituída pela agropecuária e, em menor escala, pela expansão urbana. Esse fenômeno também é evidenciado na Tabela 3, a qual mostra a variação da área ocupada, em km², por floresta, agropecuária e zona urbana ao entre 1985 e 2022.

Tabela 3. Área, em km², ocupada por florestas, pela agropecuária e zona urbana em Canavieiras/BA entre 1985 e 2022

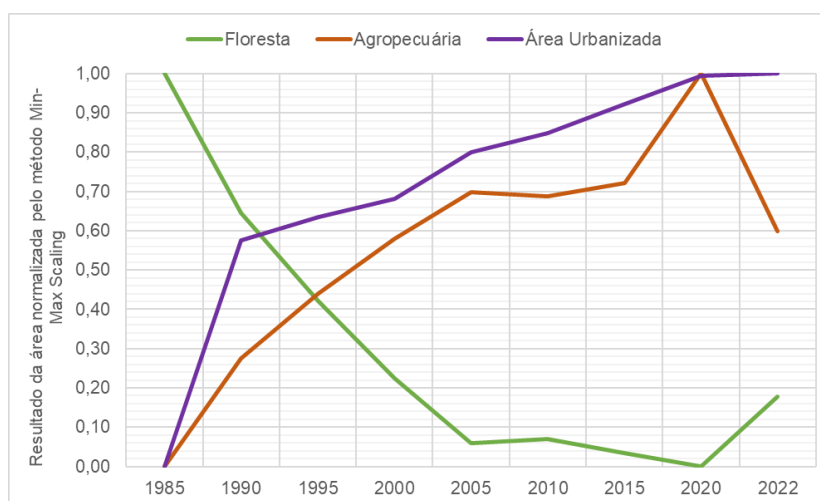
ANO	FLORESTA	AGROPECUARIA	ÁREA URBANIZADA
1985	916,68	293,35	1,14
1990	787,83	440,50	3,14
1995	706,54	528,32	3,35
2000	635,74	602,36	3,51
2005	575,46	665,56	3,92
2010	579,49	660,12	4,09
2015	566,68	677,92	4,35
2020	554,30	827,18	4,60
2022	618,79	613,13	4,62

Fonte: Mapbiomas, 2022

Analisando a Tabela 3, nota-se uma diminuição das áreas de florestas e um aumento nas áreas ocupadas pela agropecuária e pela zona urbana. O Gráfico 1, derivado da normalização⁴ dos dados da Tabela 3, ilustra o padrão evolutivo dessas mudanças ao longo do período mencionado, mostrando claramente a tendência de transformação do uso e ocupação do solo em Canavieiras.

⁴ O processo de normalização empregado foi realizado por meio do método Mínimo-Máximo *Scaling*. O objetivo foi garantir que os dados estejam em uma escala comparável, facilitando a análise.

Gráfico 1. Relação da área ocupada por floresta, agropecuária e zona urbana no município de Canavieiras/BA entre 1985 e 2022



Fonte: Adaptado do MapBiomias, 2022

Analisando o Gráfico 1, observa-se um aumento nas áreas ocupadas pela agropecuária e pela zona urbana a partir de 1985, enquanto o espaço ocupado pelas florestas reduz progressivamente. Essa relação demonstrou valores significativos de correlação negativa, indicando que, à medida que o valor de uma variável aumenta, a outra diminui. A correlação de Spearman⁵ para a agropecuária foi de -1,00 (muito forte) e para as áreas urbanas foi de -0,82 (forte).

Esses valores elevados de correlação negativa sugerem uma forte relação inversa entre o aumento das áreas ocupadas pela agropecuária e pela zona urbana e a diminuição das áreas de florestas ao longo do período analisado. Isso sugere que o crescimento desses setores está associado à redução das áreas florestais em Canavieiras.

Comparando os anos de 1985 e 2022, é possível notar uma diminuição de 32,5% nas áreas de floresta e um aumento de 109,0% nas áreas destinadas à agropecuária. Vale ressaltar que, embora ocupem uma parcela menor em comparação à agropecuária, as áreas urbanas cresceram quatro vezes mais durante o período analisado.


Outro aspecto apresentado no Gráfico 1 é o gradual aumento das áreas de floresta a partir de 2020. Além disso, observa-se também uma redução na área ocupada pela agropecuária e uma estabilização do crescimento das áreas urbanas sugerindo possíveis esforços de conservação ou o uso mais eficiente da terra ou um possível controle do processo de urbanização. No entanto, esta avaliação está além do escopo deste trabalho

⁵ Como os valores de área ocupada por florestas não apresentam uma distribuição normal (valor-p = 0,048 < 0,05), foi utilizado o coeficiente de correlação de Spearman.

6.2. CARACTERIZAÇÃO DO DESMATAMENTO DE FLORESTAS EM CANAVIEIRAS

Para esta análise, foram utilizados os *shapefiles* de alertas de desmatamento registrados em Canavieiras entre 2019 e 2022. Estes dados foram obtidos do projeto MapBiomias Alerta (2022), um sistema de validação e refinamento de alertas de desmatamento com imagens de alta resolução. Vale salientar que os dados são públicos e gratuitos. O Gráfico 2 exibe o número de alertas de desmatamento registrados em Canavieiras entre 2019 e 2022.

Gráfico 2. Quantidade de alertas de desmatamentos registrados em Canavieiras/BA entre 2019 e 2022



Fonte: Adaptado MapBiomias Alerta, 2022

Com base no Gráfico 2, percebe-se um crescimento no número de alertas de desmatamento até 2020, evidenciado também por meio do aumento da densidade de desmatamento na região, conforme dados apresentados na Tabela 4 e visualizado na Figura 21, no Apêndice IV. Após este período, há uma redução nos registros.

Tabela 4. Densidade de alertas de desmatamento por área de cobertura florestal em Canavieiras durante o período de 2019 e 2022


Ano anterior	Quantidade de alertas	Área de cobertura florestal (km ²)	Densidade (quantidade de alertas/km ²)
2019	23	552,05	0,042
2020	37	554,30	0,067
2021	29	567,73	0,051
2022	14	618,79	0,023

Fonte: MapBiomias Alerta, 2022

Segundo os dados da Tabela 4, a densidade média de alertas de desmatamento na região é de 0,046 alertas por km², destacando-se o ano de 2020 com um pico na taxa de desflorestamento. A Figura 21 revela que esse pico ocorre na região central do município, em torno de uma rodovia/estrada. Salienta-se que este fator de risco é considerado estatisticamente significativo em 2020, como evidenciado na Figura 18, presente no Apêndice III.

O Gráfico 3 mostra a área desmatada em Canavieiras, em hectares, no período entre 2019 e 2020 evidenciando as variações no desmatamento ao longo desses anos.

Gráfico 3. Área de floresta desmatada em Canavieiras, em hectares, entre 2019 e 2022



Fonte: Adaptado do MapBiomias Alerta, 2022

Ao analisar o Gráfico 3, percebe-se que o ano de 2019 apresentou a maior área de desmatamento de todo o período, totalizando 312,65 hectares. No entanto, a partir desse ponto, houve uma redução na área desmatada, culminando em 2022 com o valor de 58,13 hectares, o que corresponde a uma diminuição de 81,41% no desmatamento florestal.

Essa diminuição pode ser resultado de políticas de conservação eficazes ou maior fiscalização ambiental ou mudanças nas práticas de uso do solo, destacando a importância das ações de controle e preservação na região. No entanto, o estudo deste fato está além dos objetivos deste trabalho.

A Tabela 5 detalhada a área ocupada pelos alertas de desmatamento, segundo a declividade local. Essa análise permite identificar como o desmatamento varia em relação às características topográficas da região, destacando áreas mais suscetíveis à degradação ambiental.

Tabela 5. Área dos alertas de desmatamento, segundo a declividade local, no município de Canavieiras/BA

Declividade	Área (ha)	%
Suave ondulado	332,84	45,26
Plano	218,81	29,75
Ondulado	144,18	19,60
Forte ondulado	38,68	5,26
Montanhoso	0,94	0,13
Total	735,45	100,00

Fonte: Adaptado do MapBiomias Alerta e SRTM, 2022

De acordo com a Tabela 5, 75,01% dos alertas de desmatamento ocupam terrenos suavemente ondulados e planos, evidenciando a predominância de desmatamento nessas áreas, que neste estudo são consideradas um fator de risco, devido à maior facilidade de acesso e uso do solo para atividades agropecuárias e outras formas de ocupação humana.

A Tabela 6 mostra a distribuição de frequência dos tamanhos das áreas desmatadas em Canavieiras, proporcionando uma análise detalhada das dimensões das áreas afetadas pelo desmatamento, permitindo identificar a prevalência de desmatamento em diferentes escalas, desde pequenas áreas até grandes porções de terra. Essa informação é crucial para entender os padrões de desmatamento na região, ajudando a identificar se o processo está ocorrendo de maneira mais difusa, em pequenas áreas, ou concentrado em grandes blocos.

Tabela 6. Área desmatada, em hectares, por classe de tamanho, registrada em Canavieiras/BA entre 2019 e 2022

Área de desmate (ha)	Quantidade	%
0,24-20,24	96	94,12
20,24-40,24	4	3,92
40,24-60,24	1	0,98
80,24-100,24	1	0,98
Total Geral	102	100,00

Fonte: Adaptado do MapBiomias Alerta, 2022

De acordo com a Tabela 6, observa-se que mais de 94% da área desmatada em Canavieiras está concentrada em tamanhos relativamente pequenos, variando entre 0,24 e 20,24 hectares. Isso sugere que a remoção da vegetação nativa é mais prevalente em áreas de menor extensão.

Além disso, é perceptível que a distribuição de frequência apresentada exibe uma assimetria positiva (5,21⁶). A assimetria apresentada indica uma concentração maior de registros de alertas de desmatamento com áreas menores do que o valor médio (7,28 ha), com uma cauda longa em direção alertas com registros de desmatamento máximos (97,71 ha), que ocorrem com menor frequência.

6.3.RESULTADOS DECORRENTES DA ANÁLISE DE REGRESSÃO ESTATÍSTICA BINOMIAL

Para identificar *hotspots* de desmatamento no município de Canavieiras, foi elaborada a Tabela 7. Esta tabela apresenta os fatores de risco de desmatamento considerados estatisticamente significantes (valor-p < 0,05) entre 2019 e 2022, juntamente com seus respectivos coeficientes.

Os resultados, obtidos por meio da regressão binomial e detalhados no Apêndice III, mostram quais fatores têm maior influência na ocorrência de desmatamento durante o período analisado, permitindo a identificação das áreas mais vulneráveis.

Tabela 7. Fatores de risco de desmatamento considerados estatisticamente significantes no município de Canavieiras/BA e seus coeficientes e intercepto para o período entre 2019 e 2022

Período	Fator de risco	Coeficientes	Intercepto
2019	Pastagem	1,0765	-9,0233
	Áreas com declividade suave ondulada/plana	0,8919	
	Área sem RL	0,7407	
	Área com CAR	0,7414	
2020	Áreas desmatadas em 2019	1,6246	-8,3524

⁶ Valor obtido por meio do cálculo do coeficiente de assimetria de Pearson onde: se o valor for maior que 0, a distribuição apresenta assimetria positiva; se for menor que 0, a assimetria é negativa; e, se for igual a 0, a distribuição é simétrica.

Período	Fator de risco	Coeficientes	Intercepto
	Mosaico de Usos	1,8385	
	Rodovia	-1,7030	
	Área sem APP	1,398	
	Área com CAR	0,6233	
2021	Áreas desmatadas em 2020	1,4561	
	Pastagem	-0,6532	
	Mosaico de Usos	1,4216	-7,6507
	Área sem APP	0,4977	
	Área sem RL	0,4431	
	Área com CAR	1,1902	
2022	Agricultura	1,9704	
	Mosaico de Usos	0,4557	
	Áreas com declividade suave ondulada/plana	-0,4675	-6,7585
	Área sem APP	0,6600	
	Área com CAR	0,4571	

Fonte: Figuras 17 a 20 situadas no Apêndice III

A partir da análise da Tabela 7, percebe-se a recorrência de certos fatores de risco para o desmatamento em Canavieiras. Destacam-se entre eles: áreas com CAR (4x), mosaico de usos e áreas sem APP (3x). Essa repetição sugere a relevância desses fatores como influências significativas para o desmatamento na região. Além desses, outros fatores relevantes incluem as pastagens (2x), áreas com declividade suave ondulada/plana (2x) e ausência de reserva legal (2x).

Com base nos valores apresentados na Tabela 7, foi determinado o Valor de Risco Local (VRL) para cada célula do *grid* na área de estudo, assim como calculada a média e o desvio padrão, os quais foram utilizados para classificar cada célula de acordo com o esquema descrito no Quadro 7.

A Tabela 8 apresenta as taxas mínima, máxima, média e o desvio padrão dos dados de VRL referentes ao período de 2019 a 2022. Esses indicadores são fundamentais para compreender como o risco de desmatamento varia e se distribui na área de estudo ao longo do tempo, facilitando na identificação de *hotspots* de desmatamento.

Tabela 8. Taxa mínima, máxima, média e desvio padrão do conjunto de dados de VRL de 2019 a 2022 encontrados em Canavieiras/BA

Período	Mínimo	Máximo	Média	Desvio Padrão
2019	1,00	30,28	11,28	8,53
2020	0,34	240,90	14,75	16,47
2021	0,81	149,71	7,63	8,64
2022	0,63	34,58	1,97	1,02

Fonte: Próprio autor, 2022

Ao analisar a Tabela 8, observa-se que os anos de 2020 e 2021 se destacam em relação aos demais períodos. Em 2020, o Valor de Risco Local (VRL) variou entre 0,34, correspondente às células com menor risco, e 240,90, referente às células com maior risco. Isso indica que as células com maior risco apresentaram uma taxa de desmatamento esperada 240,90 vezes superior à das células com menor risco. O valor médio do risco nesse ano foi de 14,75, com um desvio padrão de 16,47.

Em 2021, houve um aumento de 138,23% na taxa mínima do VRL, o que indica um incremento no nível de risco em relação ao ano anterior. Esse aumento na taxa mínima sugere que mesmo as áreas com menor risco apresentaram um aumento significativo em comparação com 2020. Por outro lado, a taxa máxima do VRL reduziu em 37,85%, indicando uma diminuição na intensidade do risco nas áreas de maior risco.

Essa combinação de aumento no risco mínimo e redução no risco máximo reflete mudanças na distribuição e variabilidade dos níveis de risco de desmatamento na região, o que pode estar associado a alterações nas práticas de uso da terra ou nas condições ambientais durante o período. Adicionalmente, observam-se taxas de desvio padrão superiores à média em 2020 e 2021. Essa observação sugere uma dispersão mais ampla nos dados de VRL, indicando uma maior variabilidade nos níveis de risco de desmatamento na região entre 2020 e 2021.

Ao comparar as taxas médias do risco de desmatamento e a área de cobertura florestal em Canavieiras entre 2020 e 2022 (Tabela 3), observa-se uma relação inversamente proporcional entre a taxa média de risco de desmatamento e a área de cobertura florestal, conforme mostra a Tabela 9.

Tabela 9. Comparação entre a taxa média de risco de desmatamento e a área de cobertura florestal em Canavieiras entre 2020 e 2022

Período	Taxa média de risco de desmatamento	Área de cobertura florestal
2019	11,28	552,05
2020	14,75	554,30
2021	7,63	567,73
2022	1,97	618,79

Fonte: Próprio autor, 2022

De acordo com a Tabela 9, observa-se que a área de cobertura florestal em Canavieiras aumentou à medida que houve redução do risco de desmatamento neste município. Essa observação sugere uma possível correlação entre as medidas de mitigação do desmatamento (que reduzem o risco de desflorestamento) e a preservação da cobertura florestal em Canavieiras.

Quanto à classificação das células do grid, foram obtidas as seguintes distribuições, conforme apresentado na Tabela 10 e ilustrado nas Figuras 22, 23, 24 e 25 no Apêndice V. Essas representações visuais detalham a classificação das células de acordo com os diferentes níveis de risco, proporcionando uma análise mais clara e intuitiva das variações espaciais e temporais do risco de desmatamento. Esse detalhamento facilita a identificação de padrões e tendências, essenciais para a gestão e mitigação do desmatamento na região.

Tabela 10. Porcentagem de células classificadas no *grid* como baixo, médio, alto e altíssimo risco entre 2019 e 2022

Período	Risco (%)			
	Baixo	Médio	Alto	Altíssimo
2019	62,34	23,93	0	13,73
2020	72,02	12,18	15,72	0,07
2021	66,60	19,78	9,75	3,88
2022	76,92	0,69	19,36	3,03

Fonte: Próprio autor, 2022

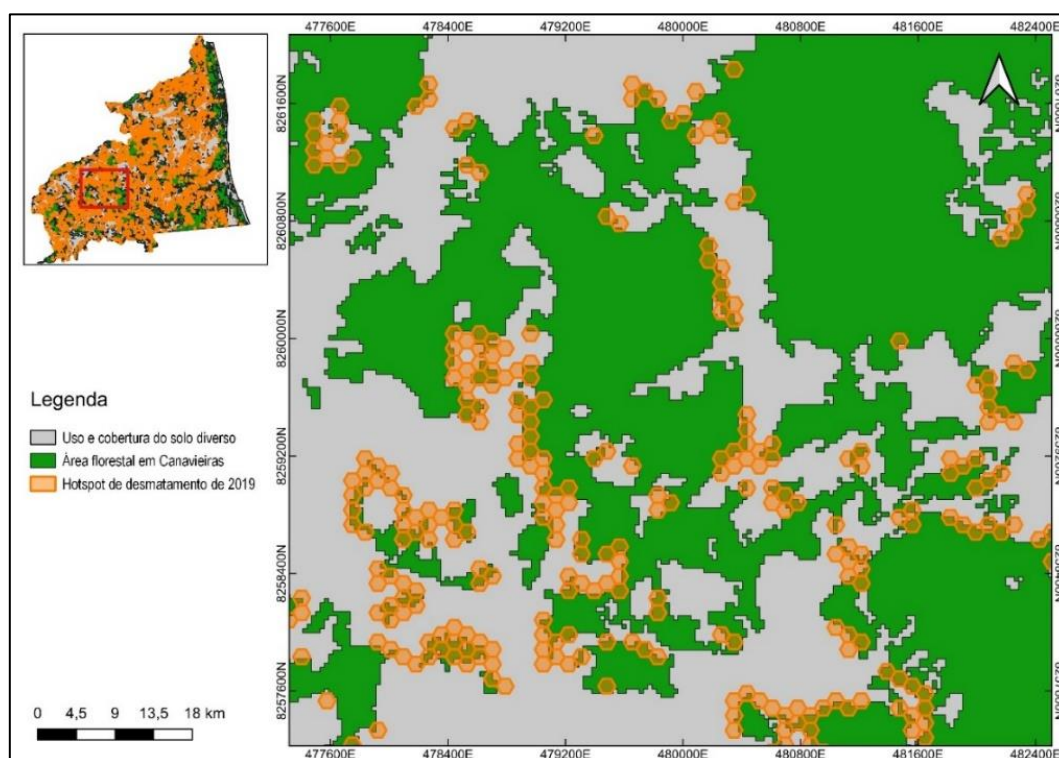
Ao examinar os dados da Tabela 10, constata-se que, em 2022, mais de 76% das áreas florestais de Canavieiras foram categorizadas com baixo e médio risco de

desmatamento, enquanto menos de 23% foram classificadas com alto e altíssimo risco. Essa distribuição sugere que a maioria das áreas florestais da região enfrenta um nível relativamente baixo ou moderado de ameaça de desmatamento. No entanto, é importante notar que uma pequena parcela dessas áreas corre um grande risco de ser desflorestada.

6.4. MAPAS DE *HOTSPOTS* DE DESMATAMENTO GERADOS PELA MODELAGEM RTM PARA OS ANOS DE 2019 A 2022

A seguir, são exibidas as Figuras 13, 14, 15 e 16, que ilustram os resultados da modelagem RTM. Essas figuras destacam os *hotspots* de desmatamento, com indícios de ilegalidade, identificados nas áreas florestais de Canavieiras/BA entre os anos de 2019 e 2022. Cada figura representa um ano específico e mostra a distribuição dos *hotspots* ao longo do tempo, oferecendo uma visão detalhada das áreas mais críticas e das tendências de desmatamento ao longo do tempo.

Figura 13. *Hotspots* de desmatamento em Canavieiras/BA em 2019

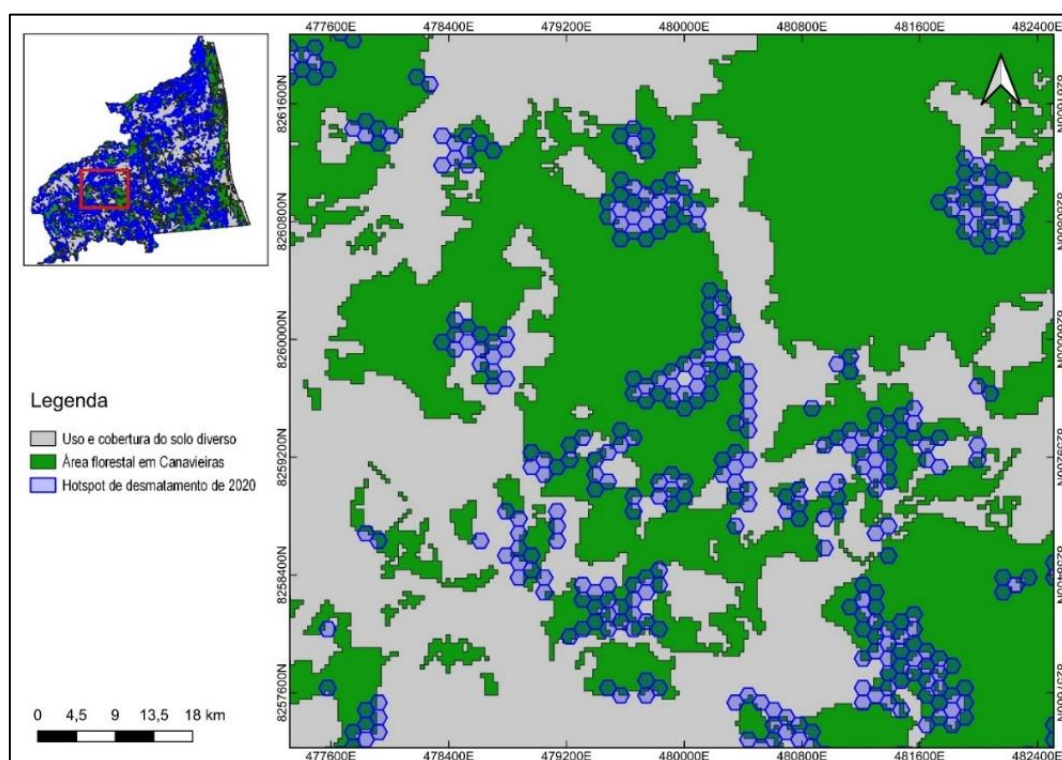


Fonte: Próprio autor, 2022

Ao analisar a Figura 13, observa-se que os *hotspots* de desmatamento de 2019 apresentam um padrão interessante: estão localizados nas bordas dos fragmentos

florestais e também em clareiras. Essa distribuição indica que o desmatamento tende a ocorrer nas bordas dos fragmentos florestais e nas áreas de abertura já existentes, possivelmente facilitado pela proximidade com regiões previamente desmatadas (Bush; Gallon, 2017). Esse padrão pode refletir estratégias de desmatamento que buscam expandir as áreas desmatadas em direção aos fragmentos florestais adjacentes, tornando-as mais vulneráveis à devastação florestal.

Figura 14. *Hotspots* de desmatamento em Canaveiras/BA em 2020

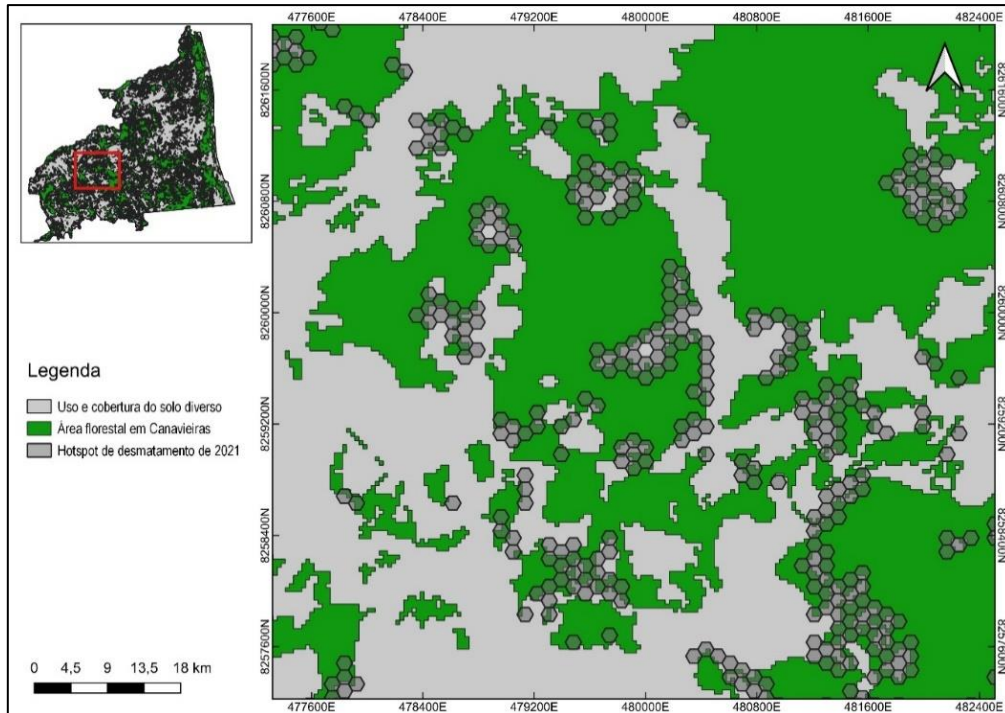


Fonte: Próprio autor, 2022

Ao analisar a Figura 14, percebe-se que 2020 mantém um padrão semelhante ao de 2019, embora haja pequenas mudanças na localização dos *hotspots* de desmatamento, refletindo a dinâmica dessa atividade no ambiente. Regiões que eram classificadas como *hotspots* em 2019 deixam de ser reconhecidas dessa forma em 2020, enquanto outras áreas que antes não eram previstas começam a ser identificadas como *hotspots* de desmatamento.

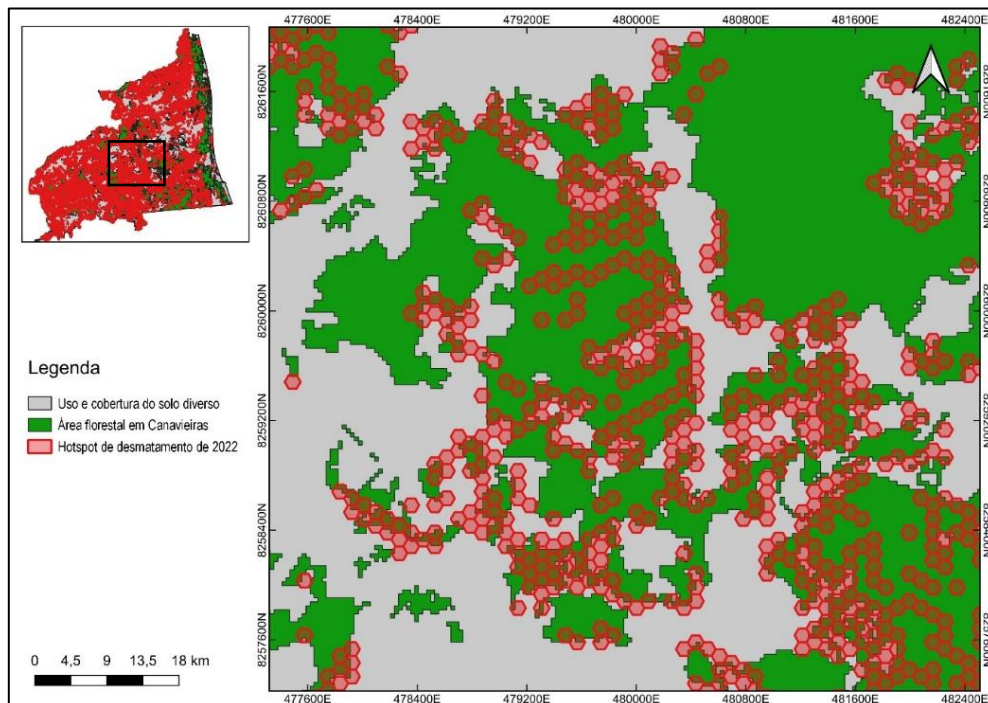
O mesmo padrão pode ser observado no ano de 2021 (Figura 15). Essa mudança pode indicar uma adaptação nas práticas de desmatamento, sugerindo que os agentes envolvidos estão explorando novas áreas, possivelmente em resposta a fatores econômicos, sociais ou físicos (ambientais).

Figura 15. Hotspots de desmatamento em Canavieiras/BA em 2021



Fonte: Próprio autor, 2022

Figura 16. Hotspots de desmatamento em Canavieiras/BA em 2022



Fonte: Próprio autor, 2022

A Figura 16 revela uma situação preocupante: a interiorização dos *hotspots* de desmatamento. Nas Figuras 13, 14 e 15, observa-se que os *hotspots* estavam predominantemente localizados nas bordas dos fragmentos florestais e nas clareiras. No

entanto, em 2022, os eles começaram a aparecer no interior dos fragmentos florestais, indicando um aumento do risco de desmatamento nessas regiões.

Essa mudança pode acarretar uma série de problemas para a biodiversidade, afetando ecossistemas locais, a fauna e a flora, além de comprometer serviços ambientais essenciais. Além disso, a redução das áreas florestais pode impactar negativamente a vida humana, como a redução da disponibilidade de recursos naturais e da qualidade do ar, além de aumentar a vulnerabilidade das comunidades locais às mudanças climáticas.

A situação observada na Figura 16 é confirmada pelos dados da Tabela 10, que indicam um aumento das áreas classificadas como de alto risco entre 2021 e 2022. Esse crescimento nas áreas de alto risco ressalta a urgência em abordar o desmatamento, uma vez que a interiorização dos *hotspots* pode resultar em impactos negativos mais amplos para os ecossistemas e as comunidades locais. Além disso, a ampliação dessas áreas de risco pode indicar uma tendência alarmante de degradação ambiental.

Ao analisar a Figura 8, nota-se que os fragmentos florestais em Canavieiras estão cercados por atividades agropecuárias, um fator de risco considerado significativo para o desmatamento neste estudo. Observa-se que os *hotspots* de desmatamento estão localizados nas áreas de transição entre os fragmentos florestais e os ambientes não florestais antropizados.

6.5. RESULTADOS DA AVALIAÇÃO DA CAPACIDADE PREDITIVA DA MODELAGEM RTM NA IDENTIFICAÇÃO DE *HOTSPOTS* DE DESMATAMENTO

Em relação ao uso da modelagem RTM para prever *hotspots* de desmatamento, com base na avaliação realizada pela métrica Taxa de Acerto (*Hit Rate* - HR), foi elaborada a Tabela 11.

Tabela 11. Taxa de acerto na previsão de alertas de desmatamento em Canavieiras/BA com um intervalo de um ano entre as faixas de previsão

Hotspots de:	Com alertas de:	Taxa de acerto (%)
2019	2020	61,29
2020	2021	76,92
2021	2022	64,29
Média		67,29

Fonte: Próprio autor, 2022

Conforme a Tabela 11, a modelagem RTM conseguiu prever aproximadamente 67,29% dos alertas de desmatamento dos anos seguintes, ressaltando a eficácia da acurácia do modelo desenvolvido em prever áreas com potencial de desmatamento na cidade de Canavieiras.

No entanto, devido a algumas limitações da Taxa de Acerto, buscou-se avaliar a modelagem RTM por meio do Índice de Acurácia Preditiva (*Predictive Accuracy Index – PAI*). Os resultados obtidos dessa avaliação estão apresentados na Tabela 12, que fornece uma análise detalhada da acurácia preditiva da modelagem RTM para previsão de *hotspots* de desmatamento.

Tabela 12. Resultados do Índice de Acurácia Preditiva (PAI) para a previsão de alertas de desmatamento em Canavieiras/BA entre 2019 e 2022

Período	Taxa de Acerto (%)	Relação a_{t1}/A_t (%)	PAI
2019	61,29	13,73	4,46
2020	76,92	15,79	4,87
2021	64,29	13,63	4,72
2022	66,67	22,4	2,98

Fonte: Próprio autor, 2022

Conforme mostrado na Tabela 12, o período de 2020 a 2021 apresentou a maior acurácia preditiva em comparação com os outros períodos analisados. No entanto, é importante destacar que os demais períodos também mostraram uma boa acurácia.

Embora o Índice de Acurácia Preditiva (PAI) represente uma melhoria em relação à Taxa de Acerto, ele não leva em conta as variações nos padrões de risco ao longo do tempo, o que pode afetar sua precisão. Para avaliar a precisão da modelagem RTM na previsão de *hotspots* de desmatamento em Canavieiras, foi utilizado o Índice de Taxa de Recaptura (RRI), conforme mostrado na Tabela 13.

Tabela 13. Resultados do RRI para avaliar a precisão do modelo RTM na previsão de áreas suscetíveis ao desmatamento em Canavieiras/BA durante o período de 2019 a 2022.

Período	RRI
2019 e 2020	1,09

Período	RRI
2020 e 2021	0,97
2021 e 2022	0,62
Média	0,89

Fonte: Próprio autor, 2022

O RRI neste estudo foi calculado como a razão entre o PAI do período 2 e o PAI do período 1 (PAI_2 / PAI_1), seguindo a metodologia desenvolvida por Drawve (2016). Em média, a modelagem RTM não alcançou uma precisão tão alta ($0,89 < 1,0$). Porém, o modelo demonstrou maior precisão nas previsões de desmatamento para o ano de 2020, onde o RRI foi superior a 1. De maneira geral, pode-se concluir que a modelagem RTM foi relativamente precisa na previsão de *hotspots* de desmatamento.

6.6. RESULTADOS DA MODELAGEM RTM PARA A ORIENTAÇÃO E PLANEJAMENTO DAS ATIVIDADES POLICIAIS

Ao avaliar o planejamento e a execução do policiamento em relação aos *hotspots* de desmatamento previstos, constatou-se que os *hotspots* estão, em média, mais dispersos no que diz respeito ao grau de compactação. Esses resultados são detalhados na Tabela 14 e ilustrados nas Figuras 13 a 16.

Tabela 14. Resultados da APR para avaliar o grau de compactação dos *hotspots* de desmatamento em Canavieiras/BA durante o período de 2019 a 2022.

Período	APR
2019	0,044
2020	0,050
2021	0,047
2022	0,049
Média	0,0475

Fonte: Próprio autor, 2022

Essa dispersão pode ser atribuída ao elevado grau de fragmentação da área florestal de Canavieiras, conforme ilustrado na Figura 8. No que diz respeito a estabilidade e a

fluidez dos *hotspots* de desmatamento ao longo do tempo em Canavieiras, foi elaborada a Tabela 15.

Tabela 15. Avaliação da estabilidade dos *hotspots* de desmatamento em Canavieiras/BA, segundo o DVI, durante o período de 2019 a 2022.

Período	DVI
2019/2020	0,59
2020/2021	0,07
2021/2022	0,33
Média	0,33

Fonte: Próprio autor, 2022

Ao examinar os dados da Tabela 15, foi notado que os *hotspots* de desmatamento permaneceram relativamente constantes de 2019 a 2022.

7. DISCUSSÃO

A criminologia ambiental, que fundamenta este estudo, sugere que crimes não ocorrem de forma aleatória, mas seguem padrões previsíveis (Perry *et al*, 2013). Esses padrões são influenciados por fatores ambientais e socioeconômicos, que contribuem para a concentração de crimes em locais específicos, conforme abordado pelas quatro teorias da criminologia ambiental (Perry *et al*, 2013; Andresen, 2014).

Em particular, a Teoria da Geometria do Crime destaca como o ambiente construído influencia o padrão geográfico das ocorrências criminais (Andresen, 2014). Assim, a identificação de fatores ambientais e/ou socioeconômicos são essenciais para a implementação de estratégias eficazes de fiscalização e controle do crime.

Com base na Teoria da Geometria do Crime, este estudo utilizou a modelagem RTM para identificar e prever *hotspots* de desmatamento em Canavieiras/BA. Embora o RTM seja amplamente aplicado na previsão de crimes em áreas urbanas (Marchment; Gill, 2021), este trabalho buscou adaptá-lo para o contexto rural, semelhante ao estudo de Cowan *et al*. (2020), que aplicou o modelo para prever crimes ambientais. No entanto, este estudo concentrou-se especificamente no desmatamento ilegal em uma porção do bioma da Mata Atlântica.

Para tanto, foram considerados os fatores de risco para o desmatamento em florestas tropicais identificados por Geist e Lambin (2001) e outros autores, visando identificar áreas de alto risco de desmatamento. Conforme os resultados apresentados, alguns fatores de risco mostraram recorrência significativa para o desmatamento em Canavieiras. Essa repetição sugere a importância desses fatores como influências-chave no desmatamento da região. Além disso, a análise da Tabela 7 revela a complexidade da interação e variação dos fatores de risco de desmatamento entre 2019 e 2022, corroborando os estudos de Geist e Lambin (2001).

Isso pode dificultar o desenvolvimento de políticas públicas e ações padronizadas de combate, exigindo uma abordagem mais abrangente por parte dos órgãos governamentais (Geist; Lambin, 2001), incluindo as forças policiais, no enfrentamento ao desmatamento. No entanto, a recorrência do desmatamento em áreas com CAR em todos os períodos analisados indica que as ações de fiscalização devem se concentrar prioritariamente em áreas privadas.

Ademais, foi constatado que mais da metade dos alertas de desmatamento ocorre em terrenos relativamente planos (Tabela 5), destacando a predominância dessa prática nessas áreas, assim como foi observado por Marchesan *et al* (2016). Percebe-se que a segmentação das áreas desmatadas com base na declividade pode oferecer insights valiosos para a definição de estratégias de manejo e proteção ambiental, especialmente em regiões mais vulneráveis ao desmatamento.

Ao analisar o padrão de distribuição de frequência dos tamanhos das áreas desmatadas em Canavieiras, percebe-se que mais de 94% da área desmatada está concentrada em terrenos de pequena extensão, apresentando uma assimetria positiva na distribuição de frequência dos dados de alertas de desmatamento. Esse fato evidencia um padrão comumente observado em dados relacionados a crimes.

De acordo com o Instituto Nacional de Justiça dos Estados Unidos (NIJ, 1999), os eventos criminais tendem a seguir uma distribuição assimétrica positiva, sendo os *hotspots* criminais manifestações geográficas dessa assimetria. Assim, é razoável supor que os desmatamentos também possam se agrupar, formando *hotspots*, assim como ocorre com os crimes convencionais.

Em relação à distribuição dos alertas de desmatamento no espaço (Figura 21) durante o período de estudo (2019-2022), observa-se que os alertas estão relativamente dispersos, afetando diferentes partes do município, com uma aparente concentração na porção centro-sul. No entanto, em 2020, os alertas de desmatamento se concentraram na

região central do município, sinalizando uma mudança temporária na dinâmica do desmatamento em Canavieiras.

Após o pico registrado em 2020, houve uma diminuição gradual na densidade dos alertas nos anos seguintes, o que pode refletir mudanças nas dinâmicas locais de uso do solo. Essa variação ao longo do período ressalta a complexidade da dinâmica do desmatamento, conforme discutido por Geist e Lambin (2001), destacando a necessidade de uma análise contínua dos fatores de risco que influenciam essas flutuações no desmatamento.

No tocante a classificação das células do *grid*, verifica-se que os resultados obtidos estão em consonância com estudos realizados por Moreto, Piza e Caplan (2014), Daley *et al.* (2016) e Dugato, Calderoni, Berlusconi (2020), mostrando que as áreas ocupadas por células classificadas como de alto ou altíssimo risco (ou seja, os *hotspots*) representam uma porcentagem menor em comparação com aquelas ocupadas por células classificadas com risco médio ou baixo em relação a área total.

Essa distribuição sugere que a maioria das áreas florestais da região enfrenta um nível relativamente baixo ou moderado de ameaça de desmatamento. Essas informações são de extrema importância no planejamento de ações operacionais e estratégicas. Por exemplo, a região identificada como de altíssimo risco (*hotspots*) pode requerer intervenções prioritárias para mitigar a ocorrência de desmatamento na área, como fiscalizações mais frequentes.

Concentrar as ações de fiscalização nas áreas de maior risco pode gerar ganhos expressivos, permitindo intervenções mais eficazes, com redução de custos e maior eficiência no combate ao desmatamento. Essa abordagem contribui para o cumprimento dos Objetivos de Desenvolvimento Sustentável (ODS) da ONU, como o ODS nº 13 (Ação contra a Mudança Global do Clima), o ODS nº 15 (Vida Terrestre) e o ODS nº 16 (Paz, Justiça e Instituições Eficazes). Dessa forma, não só promove a sustentabilidade ambiental, mas também fortalece a capacidade das instituições policiais em proteger a ordem pública diante dos impactos negativos da degradação ambiental.

Além disso, por meio da modelagem RTM, foi possível identificar que os *hotspots* de desmatamento estão predominantemente localizados nas bordas e clareiras dos fragmentos florestais. Isso evidencia que os *hotspots* de desmatamento não ocorrem de forma aleatória ou uniforme no espaço, mas seguem padrões previsíveis assim como os crimes comuns indicados por Perry *et al* (2013), Clarke e Eck (2016), Wortley e Townsley

(2017) e Andresen (2014). Essa distribuição indica a vulnerabilidade dessas regiões, especialmente devido à proximidade com áreas antropizadas e/ou já desmatadas.

Essas áreas se tornam mais vulneráveis à ação de criminosos, que se aproveitam da falta de fiscalização e da desordem social (Perry *et al*, 2013). A teoria padrão do crime destaca essa vulnerabilidade como um fator chave na atratividade para o estabelecimento e exploração ilegal dos recursos naturais. Essas regiões se tornam focos críticos para a intervenção e monitoramento, reforçando a necessidade de estratégias de policiamento específicas para proteger os fragmentos florestais existentes e mitigar os riscos associados ao desmatamento ilegal.

Além disso, ao longo dos anos analisados (2019-2022), foram observadas mudanças na localização dos *hotspots* de desmatamento. Até 2021, os focos mantiveram, em grande parte, o padrão de localização observado em 2019, com algumas modificações. Regiões que antes não eram consideradas de risco começaram a ser identificadas como novas zonas de perigo, refletindo a natureza dinâmica do desmatamento em florestas tropicais, o que deve ser levado em conta nas ações de fiscalização.

A distribuição espacial dos *hotspots* de desmatamento, analisada ao longo dos quatro anos estudados, revela uma interiorização dos focos de desmatamento em 2022 (Figura 17). Essa mudança pode indicar que as práticas de desmatamento estão se transformando, com os criminosos passando a explorar áreas que antes eram preservadas. A interiorização dos *hotspots* é especialmente alarmante, pois pode intensificar riscos de danos à biodiversidade.

A análise dos dados deste trabalho indica que o desmatamento em Canavieiras está fortemente relacionado à expansão de fronteiras agrícolas. Esse dado corrobora estudos anteriores que destacam a pressão que a expansão agrícola exerce sobre áreas de floresta (Domingues; Bermann, 2012), o que demanda uma resposta integrada entre ações policiais e políticas de desenvolvimento sustentável na proteção das áreas florestais em Canavieiras.

No contexto do policiamento ostensivo, a identificação de *hotspots* de desmatamento é fundamental para a alocação eficiente de recursos. Como descrito por Braga (2005), o mapeamento de *hotspots* auxilia na tomada de decisões estratégicas sobre onde concentrar os esforços policiais para maximizar o impacto na prevenção do crime. Nesse sentido, o RTM se apresenta como uma ferramenta valiosa para prever onde o desmatamento pode ocorrer, permitindo que as forças policiais planejem ações preventivas de forma mais eficaz. A análise prescritiva, que complementa a análise preditiva, pode

oferecer recomendações sobre as melhores práticas de intervenção, como aumentar a presença policial em áreas de maior risco.

Em relação às métricas de avaliação preditiva, a Taxa de Acerto e o Índice de Acurácia Preditiva demonstraram uma acurácia satisfatória, especialmente entre 2020 e 2021. O Índice de Taxa de Recaptura (RRI) mostrou que, apesar de a precisão geral ser moderada, o ano de 2020 apresentou um desempenho superior, com um RRI acima de 1. Isso se deve principalmente à quantidade de alertas de desmatamento registrados nesse período e à inclusão de um maior número de fatores de risco estatisticamente significativos.

Em relação às métricas de execução e planejamento do policiamento, a alta dispersão dos *hotspots* de desmatamento indicada por um baixo valor de APR, evidencia um desafio no patrulhamento das áreas florestais em Canavieiras, exigindo uma abordagem mais abrangente por parte das autoridades policiais na busca de estratégias para proteger essas regiões. Recomenda-se o envolvimento da comunidade local na preservação dessas áreas, em conformidade com o artigo 225 da Constituição Federal, que impõe a todos (Estado e sociedade) o dever de proteger o meio ambiente para as atuais e futuras gerações.

No entanto, a estabilidade dos *hotspots* de desmatamento, refletida por um valor de DVI baixo, simplifica a complexidade do policiamento nas áreas florestais de Canavieiras. Isso ocorre porque, apesar da alta dispersão dos *hotspots*, eles se mantêm consistentes ao longo do tempo. Essa consistência permite que as forças policiais planejem e direcionem suas operações de forma mais eficaz, focando em áreas identificadas como problemáticas de maneira recorrente.

8. CONCLUSÃO

Este estudo demonstrou a aplicabilidade da modelagem *Risk Terrain Modeling* (RTM) na identificação de *hotspots* de desmatamento ilegal no município de Canavieiras, Bahia. A pesquisa também ressaltou a importância da criminologia ambiental na compreensão dos padrões de desmatamento.

Assim como ocorre com crimes urbanos, o desmatamento não é aleatório, mas segue padrões previsíveis influenciados por fatores ambientais. A integração da criminologia ambiental com as ciências ambientais por meio do RTM revelou-se uma abordagem eficaz para prever áreas com alto risco de desmatamento.

Os resultados obtidos com a modelagem RTM foram significativos. Observou-se a recorrência de certos fatores de risco para o desmatamento em Canavieiras, como áreas com CAR, mosaico de usos e áreas sem APP, sugerindo a influência significativa desses fatores na região. Outros fatores importantes incluem pastagens, áreas com declividade suave ondulada/plana e ausência de áreas de reserva legal.

No entanto, o estudo revelou a complexidade da dinâmica de desmatamento em Canavieiras, com variações ao longo do tempo e mudanças nos fatores de risco entre 2019 e 2022, dificultar o desenvolvimento de políticas públicas e ações padronizadas para combater o desmatamento, exigindo uma análise mais abrangente por parte dos órgãos governamentais (incluindo as forças policiais). Entretanto, a recorrência de desmatamento em áreas com CAR indica a necessidade de priorizar a fiscalização em áreas particulares.

Em relação aos padrões de desmatamento, constatou-se que a maioria dos alertas ocorreu em áreas relativamente planas, o que reforça a influência da topografia na incidência de desmatamento. Além disso, a proximidade com áreas antropizadas, como terrenos agrícolas, foi identificada como um dos principais fatores de risco. A predominância de pequenas áreas como alvos frequentes também revela padrões que podem orientar ações mais eficazes de combate ao desmatamento.

Além disso, foi observado que os hotspots de desmatamento, inicialmente concentrados nas bordas e clareiras dos fragmentos florestais, migraram para o interior das florestas em 2022, indicando uma mudança nos padrões de risco. Essa interiorização é preocupante, pois acarreta maiores ameaças à biodiversidade e à integridade dos ecossistemas locais. Nesse contexto, as falhas do governo no monitoramento e fiscalização dessas áreas aumentam sua vulnerabilidade, tornando-as alvos atraentes para atividades ilegais, conforme discutido pela Teoria das Atividades Rotineiras.

A complexidade da dinâmica do desmatamento, juntamente com a interiorização dos *hotspots* observados em 2022, indica que as estratégias de fiscalização e proteção florestal devem ser constantemente ajustadas para garantir uma resposta eficaz às novas áreas de desmatamento que podem surgir em regiões menos monitoradas. Assim, a implementação de ações preventivas direcionadas aos *hotspots* de desmatamento é crucial para mitigar os riscos de desflorestamento e preservar os fragmentos florestais remanescentes em Canavieiras. Ao identificar esses *hotspots*, as autoridades policiais, por exemplo, podem alocar recursos de maneira mais eficiente, priorizando áreas de maior risco e implementando medidas preventivas mais eficazes.

No que se refere à análise das métricas de avaliação preditiva, como a Taxa de Acerto e o Índice de Acurácia Preditiva, os resultados foram satisfatórios. A Taxa de Acerto indicou que o RTM conseguiu prever, em média, mais de 67% dos alertas de desmatamento entre 2019 e 2022. O período de 2020 a 2021 apresentou a maior acurácia preditiva, conforme evidenciado pelo Índice de Acurácia Preditiva (PAI), destacando a eficácia do RTM na identificação de áreas vulneráveis ao desmatamento e reforçando a robustez do modelo. Além disso, a análise da Taxa de Recaptura (RRI) também corroborou a precisão relativa da modelagem RTM nos períodos avaliados.

Contudo, a dispersão dos *hotspots* indicou um desafio adicional para o patrulhamento eficiente das áreas afetadas, exigindo uma abordagem mais abrangente e integrada das forças policiais, incluindo a colaboração da comunidade local, conforme estabelecido pela Constituição Federal de 1988. Por fim, a estabilidade dos *hotspots* ao longo dos anos analisados, apesar da dispersão, facilita o planejamento de operações policiais, permitindo focar em áreas de alto risco que se mantêm recorrentes no tempo.

Assim, constatou-se que o RTM demonstrou ser uma ferramenta eficaz para orientar o planejamento das operações policiais, reforçando a necessidade de intervenções prioritárias em regiões críticas. Essas informações são cruciais para o desenvolvimento de estratégias de combate ao desmatamento, com o potencial de maximizar a eficácia das operações e reduzir os custos associados.

Salienta-se que a metodologia apresentada nesta pesquisa pode servir de base para futuros estudos e aplicações em diferentes contextos, reforçando a importância de abordagens multidisciplinares na solução de problemas ambientais complexos. Apesar dos resultados positivos, este trabalho não esgota a abordagem do assunto. Há oportunidades para aprimorá-lo, considerando novos fatores de risco e incorporando dados mais recentes e detalhados. Ademais, a replicação desta metodologia em outras regiões pode validar a sua eficácia e adaptabilidade.

Em suma, este trabalho visa não apenas contribuir para a preservação ambiental em Canavieiras/BA, mas também servir de inspiração para a elaboração de novas pesquisas e estratégias de conservação em outras áreas. Espera-se que este estudo incentive a realização de pesquisas adicionais, promova a implementação de políticas eficazes e inspire a comunidade acadêmica e os gestores públicos a continuarem explorando soluções inovadoras para os desafios ambientais.

REFERÊNCIAS

- ADEPEJU, M.; ROSSER, G.; CHENG, T. Novel evaluation metrics for sparse spatio-temporal point process hotspot predictions - a crime case study. **International Journal of Geographical Information Science**, v. 30, n. 11, p. 2133–2154, 7 abr. 2016.
- ANDRESEN, M. A. **Environmental Criminology: Evolution, Theory, and Practice**. 1. ed. Routledge, 2014.
- ARRAES, R. A. e; MARIANO, F. Z.; SIMONASSI, A. G. **Causas do desmatamento no Brasil e seu ordenamento no contexto mundial**. RESR, Piracicaba-SP, v. 50, n. 1, p. 119-140, jan./mar. 2012.
- BEATO FILHO, C. C. **Ação e estratégia das organizações policiais**. Revista O Alferes, Belo Horizonte, n. 15, p. 37-62, 2000. Disponível em: <<https://revista.policiamilitar.mg.gov.br/index.php/alferes/article/view/129>>. Acesso em: 16 jun. 2023.
- BRANDT, T. *et al.* Prescriptive Analytics in Urban Policing Operations. **Manufacturing & Service Operations Management**, 9 nov. 2021
- BRASIL. **Bolívia e Peru estão entre campeões mundiais de desmatamento**. BBC News Brasil, São Paulo, 17 nov. 2021. Disponível em: <<https://www.bbc.com/portuguese/internacional-59300251>>. Acesso em: 06 ago. 2022.
- BRASIL. **Constituição da República Federativa do Brasil de 1988**. Disponível em: <http://www.planalto.gov.br/ccivil_03/constituicao/constituicao.htm>. Acesso em: 16 fev. 2021.
- BUSCH, Jonah; GALLON, Kalif F. What Drives Deforestation and What Stops It? A Meta-Analysis. **Review of Environmental Economics and Policy**, v. 11, n. 1, p. 3–23, 2017
- CAPLAN, Joel M et al. Risk Terrain Modeling: Brokering Criminological Theory and GIS Methods for Crime Forecasting. **Justice Quarterly**, v. 28, n. 2, p. 360–381, abr. 2011
- CAPLAN, Joel M. et al. Risk Terrain Modeling for Spatial Risk Assessment. **A Journal of Policy Development and Research**, Rutgers University, v. 17, nº 1, 2015.
- CAPLAN, J. M. et al. Crime in context: Utilizing risk terrain modeling and conjunctive analysis of case configurations to explore the dynamics of criminogenic behavior settings. **Journal of Contemporary Criminal Justice**, City University of New York, v. 33, n. 2, p. 133-151, 2017.
- CAPLAN, Joel M.; KENNEDY, Leslie W. **Risk Terrain Modeling Compendium For Crime Analysis**. Newark: Rutgers Center on Public Safety, 2011. Disponível em: <https://www.rutgerscps.org/uploads/2/7/3/7/27370595/riskterrainmodelingcompendium_caplankennedy2011.pdf>. Acesso em: 10 abr. 2023.

CAPLAN, J. M.; KENNEDY, L. W.; NEUDECKER, C. H. Cholera deaths in Soho, London, 1854: Risk Terrain Modeling for epidemiological investigations. **PLOS ONE**, v. 15, n. 3, p. e0230725, 30 mar. 2020.

CARDINALE, B. J. et al. Biodiversity loss and its impact on humanity. **Nature**, v. 486, n. 7401, p. 59–67, jun. 2012.

CARDOZO, L. S. et al. Governança ambiental e percepção sobre processos participativos na reserva extrativista de Canavieiras, Bahia, Brasil. **Revista Meio Ambiente e Desenvolvimento**, v. 34, p. 125-142, 2019.

CHAINEDY, S. et al. The Utility of Hotspot Mapping for Predicting Spatial Patterns of Crime. **Security Journal**, v. 21, n. 1-2, p. 4–28, 29 jan. 2008.

CHAINEDY, S. Methods and techniques for understanding crime hotspots. In: Mapping Crime: Understanding Hot Spots. **National Institute of Justice**, Washington, DC, 2005.

CLARKE, R. V.; ECK, J. E. Crime Analysis for Problem Solvers in 60 Small Steps. Washington, DC: Office of Community Oriented Policing Services, 2016.

COUTINHO, Leopoldo Magno. **Biomias Brasileiros**. São Paulo: Oficina de Textos, 2016.

COWAN, D. et al. Applying Crime Pattern Theory and Risk Terrain Modeling to Examine Environmental Crime in Cambodia. **Journal of Contemporary Criminal Justice**, v. 36, n. 3, p. 327–350, 25 maio 2020

DALEY, D. et al. Risk terrain modeling predicts child maltreatment. **Child Abuse & Neglect**, v. 62, p. 29–38, dez. 2016.

DEAN, Warren. **A ferro e fogo: a história e a devastação da Mata Atlântica brasileira**. 1. ed. São Paulo: Cia. das Letras, 2004. 484 p.

DOMINGUES, M. S.; BERMAN, C. O arco de desflorestamento na Amazônia: da pecuária à soja. **Ambiente & Sociedade**, v. 15, p. 1–22, 1 ago. 2012.

DRAWVE, G. A Metric Comparison of Predictive Hot Spot Techniques and RTM. **Justice Quarterly**, v. 33, n. 3, p. 369–397, 16 abr. 2014.

DUGATO, M.; CALDERONI, F.; BERLUSCONI, G. Forecasting organized crime homicides: Risk terrain modeling of camorra violence in Naples, Italy. **Journal of Interpersonal Violence**, v. 35, n. 19-20, p. 4013-4039, 2020

ECK, John E. Crime hot spots: what they are, why we have them, and how to map them. In: **Mapping crime: understanding hot spots**. 2005. Disponível em: <www.ojp.usdoj.gov/nij>. Acesso em: 04 abr. 2023

EMBRAPA. **Serviços ambientais**. 2018. Disponível em: <<https://www.embrapa.br/tema-servicos-ambientais/sobre-o-tema>>. Acesso em: 04 mar. 2023.

EMBRAPA. **Sistema Brasileiro de Classificação de Solos**. Brasília: Serviço de Produção de Informação, 1999. 412 p.

EMILIANO, P. C. **Fundamentos e Aplicações dos Critérios de Informação: Akaike e Bayesiano**. 2009. Dissertação (Mestrado em Estatística e Experimentação Agropecuária) Lavras, MG: Universidade Federal de Lavras, 2009.

ESTADO DA BAHIA. **Tipologia Climática Thornthwaite & Matther**. Superintendência de Estudos Econômicos e Sociais da Bahia, 1998.

FAHRIG, Lenore. Effects of Habitat Fragmentation on Biodiversity. **Annual Review of Ecology, Evolution, and Systematics**, v. 34, n. 1, p. 487–515, nov. 2003.

FAO. **Forest resources assessment (FRA) 2020 remote sensing survey**. Rome: FAO, 2022. Disponível em: <<https://doi.org/10.4060/cb9970en>>. Acesso em: 06 ago. 2022.

FAO. **The state of the world's forests 2020: forests, biodiversity and people**. Rome: FAO, 2020. Disponível em: <<https://www.unep.org/pt-br/resources/situacao-das-florestas-no-mundo-florestas-biodiversidade-e-pessoas>>. Acesso em: 06 ago. 2022.

FAO. **The state of the world's forests 2022: forest pathways for green recovery and building inclusive, resilient and sustainable economies**. Rome: FAO, 2022. Disponível em: <<https://doi.org/10.4060/cb9360en>>. Acesso em: 06 ago. 2022.

FARIAS, R. L. et al. Impacto dos assentamentos rurais no desmatamento da Amazônia. **Mercator**, v. 19, e17009, 2018. Disponível em: <

FRANCISCO FILHO, L. L.; SILVA, J. X. **Geoprocessamento aplicado à análise da distribuição espacial da criminalidade no município de Campinas (SP)**. In: Geoprocessamento e Meio Ambiente. Rio de Janeiro: Editora Bertrand Brasil, 2010.

FRANCO, Tânia; DRUCK, Graça. Padrões de industrialização, riscos e meio ambiente. **Ciência & Saúde Coletiva**, v. 3, n. 2, p. 61–72, 1998.

GEIST, Helmut J.; LAMBIN, Eric F. What drives tropical deforestation? A meta-analysis of proximate and underlying causes of deforestation based on subnational case study evidence. LUCR Report Series N. 4. Land Use and Land Cover Change, **International Geosphere-Biosphere Programme**, 2001.

GELDMANN, Jonas et al. A global-level assessment of the effectiveness of protected areas at resisting anthropogenic pressures. **Biological Sciences**, v. 114, n. 46, p. 23209-23215, 2019.

GUILLÉN, C. S. J. Criminología ambiental: un área en expansión. **Ars Iuris Salmanticensis**, v. 1, p. 33-38, 2013.

HART, Timothy. C. Investigating crime pattern stability at micro-temporal intervals: implications for crime analysis and hotspot policing strategies. **Criminal Justice Review**, v. 46, n. 2, p. 173–189, 2021.

HOLMGREN, Peter; THURESSON, Thomas. Satellite remote sensing for forestry planning - a review. **Scandinavian Journal of Forest Research**, 2008.

HOSONUMA, Noriko *et al.* An assessment of deforestation and forest degradation drivers in developing countries. **Environmental Research Letters**, 2012.

IBGE. Instituto Brasileiro de Geografia e Estatística. **Canavieiras**. Disponível em: <<https://cidades.ibge.gov.br/brasil/ba/canavieiras/panorama>>. Acesso em: 20 mar. 2023

JUVENAL, Thais Linhares; MATTOS, René Luiz Grion. O setor florestal no Brasil e a importância do reflorestamento. **BNDES Setorial**, Rio de Janeiro, n. 16, p. 3-29, 2002.

KENNEDY, L. W. *et al.* Risk clusters, hotspots, and spatial intelligence: Risk terrain modeling as an algorithm for police resource allocation strategies. **Journal of quantitative criminology**, v. 27, n. 3, p. 339–362, 2011

KENNEDY, L. W. *et al.* Vulnerability and exposure to crime: Applying risk terrain modeling to the study of assault in Chicago. **Applied spatial analysis and policy**, v. 9, n. 4, p. 529–548, 2016.

KENNEDY, L. W.; DUGATO, M. Forecasting crime and understanding its causes. Applying risk terrain modeling worldwide. **European journal on criminal policy and research**, v. 24, n. 4, p. 345–350, 2018.

KENNEDY, Leslie W.; CAPLAN, Joel M.; PIZA, Eric L. Risk clusters, hotspots, and spatial intelligence: Risk terrain modeling as an algorithm for police resource allocation strategies. **Journal of quantitative criminology**, v. 27, n. 3, p. 339–362, 2011.

KONRAD, A. C. *et al.* Green criminology: uma abordagem da criminologia nas ciências ambientais. **Revista Ibero Americana de Ciências Ambientais**, v. 11, n. 3, p. 508-518, 2020.

LEAL, Carlos Galindo; CÂMARA, Ibsen Gusmão. Mata Atlântica biodiversidade, ameaças e perspectivas. São Paulo, 2005. Disponível em: <<http://ecologia.ib.usp.br/ecovegetal/leituras/CapituloVEstadodabiodiversidadedaMataAtlantica brasileira.pdf>>

LEVINE, Ned. The “hottest” part of a hotspot: Comments on “the utility of hotspot mapping for predicting spatial patterns of crime”. **Security journal**, v. 21, n. 4, p. 295–302, 2008.

LIMEIRA, Marcio Luiz da Costa. **Proposta de policiamento inteligente: integrando modelos de localização preditiva e de roteirização eficiente de patrulhas policiais**. 2022. 94 f. Dissertação (Mestrado em Administração) – Porto Alegre, RS: Universidade Federal do Rio Grande do Sul, 2022.

LONG, J. Scott. Regression models for categorical and limited dependent variables. Beverly Hills: **Sage Publications**, 1997.

MARCHESAN, J. *et al.* Análise da relação entre a evolução florestal e a declividade utilizando imagens Landsat. **Nativa**, [S. l.], v. 4, n. 1, p. 53–57, 2016.

MARCHMENT, Z.; GILL, P. Systematic review and meta-analysis of risk terrain modelling (RTM) as a spatial forecasting method. **Crime science**, v. 10, n. 12, p. 1-12, 2021.

MAWALAGEDARA, Rachindra; OGLESBY, Robert J. The climatic effects of deforestation in South and Southeast Asia. In: MOUTINHO, Paulo. Deforestation around the world. **Croatia: IntechOpen**, 2012. p. 03-20.

MEA. **Ecosystems and their services in Millennium Ecosystem Assessment**. 2005. Disponível em: <<https://www.millenniumassessment.org/en/Framework.html>>

MILLER, G. Tyler; SPOOLMAN, Scott E. **Ciência ambiental**. 14. ed. São Paulo: Cengage Learning, 2015.

MITTERMEIER, Russell A.; FONSECA, Gustavo A. B. da. **The Atlantic Forest: history, biodiversity, threats and opportunities of the mega-diverse forest**. In: MARQUES, Marcia C. M.; GRELE, Carlos E. V. (Ed.) Switzerland: Springer, 2021. p. 06-08.

MORAES, Márcio Oliveira de. **A importância da produção de indicadores e da análise criminal para subsidiar as políticas públicas de segurança**. Dissertação (Mestrado em Segurança Pública) – Vila Velha, ES: Universidade de Vila Velha, 2016.

MORETO, W. D.; PIZA, E. L.; CAPLAN, J. M. “A plague on both your houses?": Risks, repeats and reconsiderations of urban residential burglary. **Justice Quarterly**, v. 31, n. 6, p. 1102-1126, 2014.

NASCIMENTO, D. M. C.; DOMINGUEZ, J. M. L. Avaliação da vulnerabilidade ambiental como instrumento de gestão costeira nos municípios de Belmonte e Canavieiras, Bahia. **Revista Brasileira de Geociências**. v. 39, n. 3, p. 395-408, 2009.

NASCIMENTO, N. R. B.; NASCIMENTO, P. R. T. B. Policiamento ostensivo como ferramenta de prevenção a ilícitos. **Revista Eletrônica Casa de Makunaima**, v. 1, n. 1, p. 93-101, 2018.

NJI. National Institute of Justice. **Overview of predictive policing**. Disponível em: <<https://nij.ojp.gov/topics/articles/overview-predictive-policing>>. Acesso em: 10 abr. 2023.

OHYAMA, Tomoya; AMEMIYA, Mamoru. Applying crime prediction techniques to Japan: A comparison between risk terrain modeling and other methods. **European journal on criminal policy and research**, v. 24, n. 4, p. 469–487, 2018.

PACHECO, Andrea; MEYER, Carsten. Land tenure drives Brazil's deforestation rates across socio-environmental contexts. **Nature Communications**, v. 13, n. 5759, p. 1-10, 2022.

PASSOS, D. C. da S.; PINHEIRO, M. V. B.; TEIXEIRA, Y. Y. S. Tensões de poder: a ausência estatal como elemento propulsor do Primeiro Comando da Capital e os seus avanços na Amazônia. **Revista Jurídica do Cesupa**, v. 4, n. 2, p. 235-256, 2023.

PERRY, Walter L. et al. **Predictive policing: the role of crime forecasting in law enforcement operations**. Santa Monica, CA: RAND Corporation, 2013. Disponível em: <https://www.rand.org/pubs/research_reports/RR233.html>.

PINTO et al. The role of different governance regimes in reducing native vegetation conversion and promoting regrowth in the Brazilian Amazon. **Biological Conservation**, v. 267, 2022.

PROJETO MAPBIOMAS. **Coleção 8 da série anual de mapas de cobertura e uso da terra do Brasil**. 2022. Disponível em:
<[workspace/public/collection8/mapbiomas_collection80_integration_v1](#)>.

RAMBALDI, Denise Marçal; OLIVEIRA, Daniela América Suárez. **Fragmentação de ecossistemas: causas, efeitos sobre a biodiversidade e recomendações de políticas públicas**. [Brasília]: Ministério do Meio Ambiente, 2003. Disponível em:
<<http://www.bibliotecaflorestal.ufv.br/handle/123456789/4456>>.

RAMOS, et al. Ocorrência, evolução anual de incêndios e queimadas no Brasil entre 2003 e 2018 e relação com desmatamento. **BioBrasil Revista Científica**, número especial, p. 257, 2019.

RAYMUNDO, F. de A. Policiamento ostensivo e policiamento velado: integração e assuntos correlatos. **Revista Ciência & Polícia**, v. 4, n. 1, 2023.

RAD. **Relatório Anual de desmatamento 2021**. São Paulo: Brasil MapBiomias, 2022. 126 p. Disponível em: <<http://alerta.mapbiomas.org>>.

RITCHIE, Hannah; ROSER, Max. **Deforestation and forests loss**. 2021. Disponível em:
<<https://ourworldindata.org/forests-and-deforestation>>. Acesso em: 02 mar. 2023.

RIZZATTI, M. et al. Mapeamento da COVID-19 por meio da densidade de Kernel. **Metodologias e Aprendizado**, v. 3, p. 44–53, 2020.

ROSA, Marcos Reis. **Metodologia de classificação de uso e cobertura da terra para análise de três décadas de ganho e perda anual da cobertura florestal nativa na Mata Atlântica**. Tese (Doutorado em Geografia Física) – São Paulo, SP: Universidade de São Paulo, 2021.

SALA, O. E. et al. Global biodiversity scenarios for the year 2100. **Science**, v. 287, n. 5459, p. 1770–1774, 2000.

SANTOS, R. et al. Dinâmica do desmatamento da Mata Atlântica: causas e consequências. **Revista Gestão & Sustentabilidade Ambiental**, [S. l.], v. 9, n. 3, p. 378–402, 2020.

SCRIECIU, S. Serba. Can economic causes of tropical deforestation be identified at a global level? **Ecological Economics**, v. 62, n. 3–4, p. 603–612, 2007.

SHERMAN, L. W. **Hot spots of crime and criminal careers of places**. 1995 Disponível em:
<https://www.researchgate.net/publication/241905863_Hot_Spots_of_Crime_and_Criminal_Careers_of_Places/link/0c96053a544afc5fca000000/download?_tp=eyJjb250ZXh0Ijp7ImZpcnN0UGFnZSI6InB1YmxpY2F0aW9uIiwicGFnZSI6InB1YmxpY2F0aW9uIn19>.

SILVA, W. C. P. Empregando o policiamento preditivo: construção de um modelo de risco do terreno para crimes contra o patrimônio dos Correios. **Revista Brasileira de Ciências Policiais**, v. 7, n. 2, p. 53–71, 2017

SIRVINSKAS, Luís Paulo. **Conceito de unidades de conservação**. In: Manual de direito ambiental. 16. ed. São Paulo: Saraiva Educação, 2018. p. 562-563.

SOLÓRZANO, Alexandro; BRASIL, Lucas Santa Cruz de Assis; OLIVEIRA, Rogério Ribeiro de. The Atlantic Forest ecological history: from pre-colonial times to the Anthropocene. In: MARQUES, Marcia C. M.; GRELE, Carlos E. V. (Ed.). **The Atlantic Forest history, biodiversity, threats and opportunities of the mega-diverse forest**. Switzerland: Springer, 2021. p. 25-44.

SOS MATA ATLÂNTICA. **Atlas dos remanescentes florestais da Mata Atlântica. Período 2021-2022**. Relatório técnico. São Paulo, SOS Mata Atlântica, 2023.

SOS MATA ATLÂNTICA. **Relatório anual: 2021**. São Paulo, SOS Mata Atlântica, 2021. Disponível em: <https://cms.sosma.org.br/wp-content/uploads/2022/07/Relatorio_21_julho.pdf>

TAYLOR, Ralph B. **Community criminology: fundamentals of spatial and temporal scaling, ecological indicators, and selectivity bias**. New York: New York University Press, 2015.

UCHIDA, Craig D. **A national discussion on predictive policing: defining our terms and mapping successful implementation strategies**. National Institute of Justice, Los Angeles, 2009. Disponível em: <<https://www.ojp.gov/pdffiles1/nij/grants/230404.pdf>>.

VALASIK, Matthew et al. Forecasting homicide in the red stick: Risk terrain modeling and the spatial influence of urban blight on lethal violence in Baton Rouge, Louisiana. **Social science research**, v. 80, p. 186–201, 2019.

WORTLEY, Richard; TOWNSLEY, Michael. **Environmental criminology and crime analysis: situating the theory, analytic approach and application**. 2. ed. Crime Science Series. London: Routledge, 2017.

WWF. **Forest-specialist index (fsi)**. 2022. Disponível em: <<https://livingplanetindex.org/fsi>>. Acesso em: 29 mar. 2023.

APÊNDICE I

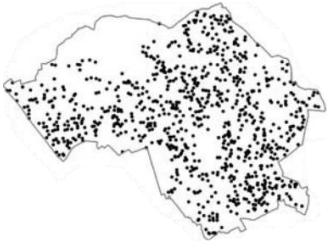
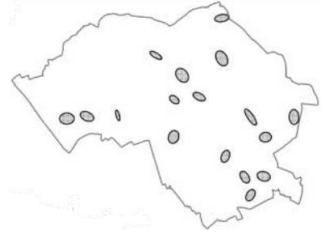
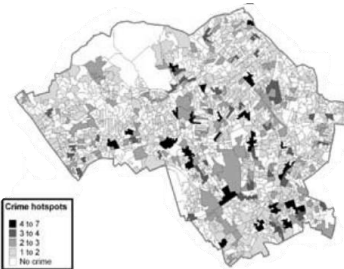
Quadro 8. Dados utilizados na construção do modelo RTM e suas fontes

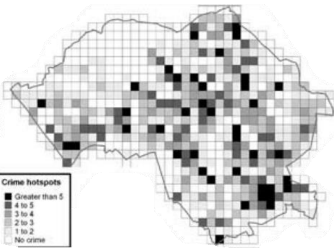
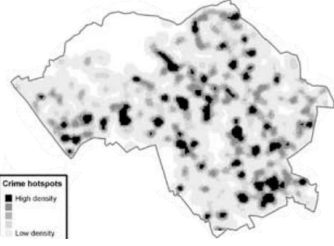
Dados utilizados	Tipo do dado	Fonte
Limite municipal de Canavieiras	<i>Shapefile</i>	IBGE
Áreas previamente desmatadas (Alertas de desmatamento)	<i>Shapefile</i>	MapBiomas Alerta
Florestas	<i>Shapefile</i>	MapBiomas
Pastagem	<i>Raster</i>	MapBiomas
Mosaico de Usos	<i>Raster</i>	MapBiomas
Agricultura	<i>Raster</i>	MapBiomas
Zona Urbana	<i>Raster</i>	MapBiomas
Silvicultura	<i>Raster</i>	MapBiomas
Estradas/Rodovias	<i>Shapefile</i>	Open Street Map
Assentamentos rurais	<i>Shapefile</i>	INCRA
Áreas planas	<i>Raster</i>	SRTM
Cicatrizes queimada	<i>Raster</i>	MapBiomas fogo
APP	<i>Shapefile</i>	Fundação Brasileira para Desenvolvimento Sustentável (FBDS)
Area de Reserva Legal (ARL)	<i>Shapefile</i>	SICAR
CAR	<i>Shapefile</i>	SICAR

Fonte: Próprio autor (2022).

APÊNDICE II

Quadro 9. Síntese das técnicas de mapeamento hotspots mais comuns, segundo
Chainey *et al.* (2008)

Técnica de mapeamento	Conceito	Vantagens	Desvantagens	Exemplo de apresentação
Mapeamento de Pontos (ou point mapping)	É uma das técnicas mais convencionais e frequentemente utilizadas para visualizar a distribuição do crime no espaço.	Fácil aplicação. Representa uma versão digital simplificada do método de marcar, por meio de pinos, eventos criminais em um mapa de parede	Dificuldade de interpretar padrões espaciais e identificar hotspots quando o conjunto de dados é extenso	
Elipses espaciais de desvio padrão (standard deviational spatial ellipses)	Método originado do mapeamento de pontos e desenvolvido para o software <i>Spatial and Temporal Analysis of Crime (STAC)</i> , que identifica clusters no mapa e cria elipses com base no desvio padrão calculado a partir das distâncias entre os pontos no mapa	Fornece detalhes sobre hotspots, incluindo tamanho, alinhamento e direção dos eventos criminais; identifica hotspots sem depender de fronteiras predefinidas, como unidades administrativas (bairros, distritos, cidades, etc.); é compatível com a maioria dos aplicativos SIG	Exige a configuração de vários parâmetros; a ausência de regras rígidas para a definição desses parâmetros pode resultar em ambiguidades e aumentar a variabilidade nos resultados finais, especialmente quando diferentes analistas utilizam o mesmo conjunto de dados; etc	
Mapeamento Temático de Unidades Administrativas (thematic mapping of administrative units)	Também conhecido como mapeamento coroplético, é uma técnica de representação cartográfica que agrupa pontos dispersos em um mapa em unidades administrativas (como bairros, distritos, cidades, estados, etc) sombreando essas	Importantes para a obtenção de informações gerais sobre padrões regionais para fins políticos e administrativos; são mapas rápidos de produzir e exigem pouco conhecimento técnico para serem interpretados; permite que o usuário determine rapidamente quais	Não evidencia padrões detalhados dentro das unidades administrativas; pode induzir equívocos na identificação de hotspots devido às disparidades no tamanho e formato das unidades administrativas; Enfrenta o desafio	

	<p>áreas conforme a quantidade de crimes nelas registrados</p>	<p>áreas têm uma alta incidência de crimes; pode ser facilmente vinculada a outras fontes de dados, como dados populacionais, aumentando sua versatilidade para análise</p>	<p>do MAUP (Modifiable Areal Unit Problem), que gera resultados diferentes com diferentes esquemas de agregação; apresenta variação no sombreado dos mapas a depender do método de divisão de intervalo escolhido (contagem igual, intervalos iguais, quebra natural, desvio padrão, quantil)</p>	
<p>Mapeamento em Grade (grid thematic mapping)</p>	<p>Esse método de mapeamento emprega áreas padronizadas e comparáveis (grids) para identificar hotspots, contando crimes por célula do grid ou calculando um valor de densidade com base na contagem e na área da célula. Ao final, é aplicado um sombreado temático conforme o valor encontrado em cada grid</p>	<p>Precisão superior na identificação de hotspots em comparação ao mapeamento temático de unidades administrativas; direciona eficazmente o policiamento para áreas que requerem intervenção policial.</p>	<p>Perda de detalhes espaciais dentro e através de cada grid; enfrenta o desafio do MAUP</p>	
<p>Estimativa de Densidade Kernel (EDK ou kernel density estimation)</p>	<p>Abordagem amplamente utilizada, na qual os pontos (delitos) são reunidos em um raio de busca determinado pelo</p>	<p>Método de análise espacial mais apropriado para a representação visual de dados criminais; oferece maior precisão</p>	<p>Ausência de padrões universais para a definição do tamanho da célula e do raio de busca; mapas gerados com</p>	

	usuário, gerando uma superfície contínua que expressa a densidade ou o volume de eventos criminosos na área designada. Um mapa suavizado é então criado, exibindo a variação na densidade de pontos/crimes em toda a região de estudo, sem a necessidade de adaptação a formas geométricas específicas	na identificação de hotspots; apresenta mapas esteticamente mais agradáveis em comparação a outras técnicas; direciona eficazmente o policiamento para áreas que requerem intervenção policial	poucos dados podem induzir interpretações equivocadas	
--	--------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------	-------------------------------------------------------	--

Fonte: Adaptado de Chainey (2005) e Chainey *et al.* (2008)

Figura 17. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2019

```

=====
Dep. Variable:      DESMATE_19  No. Observations:      98468
Model:              GLM        Df Residuals:          98455
Model Family:      Binomial    Df Model:              12
Link Function:     Logit       Scale:                 1.0000
Method:            IRLS       Log-Likelihood:        -1035.9
Date:              Fri, 18 Aug 2023  Deviance:              2071.8
Time:              02:12:13     Pearson chi2:          8.93e+04
No. Iterations:    27          Pseudo R-squ. (CS):    0.0009737
Covariance Type:   nonrobust

=====
              coef  std err      z  P>|z|    [0.025    0.975]
-----
Intercept    -9.0233    0.494   -18.249  0.000   -9.992   -8.054
AGRICULTUR  -22.2596    9.37e+04  -0.000  1.000  -1.84e+05  1.84e+05
PASTAGEM     1.0765     0.189    5.689  0.000    0.706    1.447
MOSAIC_USO   0.3246     0.171    1.893  0.058   -0.011    0.661
AREA_URBAN  -20.3866    1.13e+05  -0.000  1.000  -2.22e+05  2.22e+05
SILVICULTU   0.0912     0.513    0.178  0.859   -0.913    1.096
RODOVIA     -22.3918    2.05e+04  -0.001  0.999  -4.02e+04  4.02e+04
ASSE_RURAL  -22.3020    1.78e+04  -0.001  0.999  -3.5e+04   3.49e+04
DECLIVIDAD   0.8519     0.303    2.809  0.005    0.258    1.446
INCENDIO19  -22.3787    5.75e+04  -0.000  1.000  -1.13e+05  1.13e+05
SEM_APP      0.0103     0.275    0.038  0.970   -0.528    0.549
SEM_RL       0.7497     0.239    3.093  0.002    0.271    1.210
CAR          0.7414     0.196    3.776  0.000    0.357    1.126
=====
    
```

Figura 18. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2020

```

=====
Dep. Variable:      DESMATE_20  No. Observations:      98468
Model:              GLM        Df Residuals:          98453
Model Family:      Binomial    Df Model:              14
Link Function:     Logit       Scale:                 1.0000
Method:            IRLS       Log-Likelihood:        -2331.1
Date:              Fri, 18 Aug 2023  Deviance:              4662.1
Time:              02:19:40     Pearson chi2:          9.79e+04
No. Iterations:    25          Pseudo R-squ. (CS):    0.003918
Covariance Type:   nonrobust

=====
              coef  std err      z  P>|z|    [0.025    0.975]
-----
Intercept    -8.3424    0.345   -24.168  0.000   -9.019   -7.666
DESMATE_19   1.6246    0.516    3.146  0.002    0.612    2.637
AGRICULTUR  -21.0639    3.37e+04  -0.001  1.000  -6.61e+04  6.61e+04
PASTAGEM     0.0693     0.107    0.650  0.516   -0.140    0.278
MOSAIC_USO   1.8385    0.123    15.007  0.000    1.598    2.079
AREA_URBAN  -20.1199    4.07e+04  -0.000  1.000  -9.15e+04  9.14e+04
SILVICULTU  -0.7459     0.506   -1.475  0.140   -1.737    0.245
RODOVIA     -1.7030     0.710   -2.398  0.016   -3.095   -0.311
ASSE_RURAL  -0.1442     0.310   -0.465  0.642   -0.751    0.463
DECLIVIDAD   0.0595     0.144    0.414  0.679   -0.222    0.341
INCENDIO19  -20.9771    2.06e+04  -0.001  0.999  -4.04e+04  4.03e+04
INCENDIO20  -20.7739    5.47e+04  -0.000  1.000  -1.07e+05  1.07e+05
SEM_APP      1.3980     0.267    5.237  0.000    0.875    1.921
SEM_RL       0.0686     0.128    0.538  0.591   -0.182    0.319
CAR          0.6233     0.123    5.078  0.000    0.383    0.864
=====
    
```

Figura 19. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2021

```

=====
Dep. Variable:      DESMATE_21  No. Observations:      98468
Model:              GLM        Df Residuals:          98451
Model Family:      Binomial    Df Model:              16
Link Function:     Logit       Scale:                 1.0000
Method:            IRLS       Log-Likelihood:        -1800.8
Date:              Fri, 18 Aug 2023  Deviance:              3601.6
Time:              02:25:15     Pearson chi2:          1.00e+05
No. Iterations:    28          Pseudo R-squ. (CS):    0.002915
Covariance Type:   nonrobust

=====
              coef  std err      z  P>|z|    [0.025    0.975]
-----
Intercept    -7.6507    0.327   -23.367  0.000   -8.292   -7.009
DESMATE_19  -23.9666    1.26e+05  -0.000  1.000  -2.47e+05  2.47e+05
DESMATE_20   1.4561     0.347    4.191  0.000    0.775    2.137
AGRICULTUR  -23.4688    1.49e+05  -0.000  1.000  -2.93e+05  2.93e+05
PASTAGEM    -0.6532     0.127   -5.157  0.000   -0.901   -0.405
MOSAIC_USO   1.4216     0.130    10.929  0.000    1.167    1.677
AREA_URBAN  -21.9570    1.9e+05  -0.000  1.000  -3.72e+05  3.72e+05
SILVICULTU  -23.8667    3.07e+04  -0.001  0.999  -6.03e+04  6.02e+04
RODOVIA     -23.6028    3.28e+04  -0.001  0.999  -6.43e+04  6.42e+04
ASSE_RURAL  -23.9604    2.9e+04  -0.001  0.999  -5.69e+04  5.68e+04
DECLIVIDAD   0.1488     0.164    0.908  0.364   -0.470    0.172
INCENDIO19  -23.2979    9.15e+04  -0.000  1.000  -1.79e+05  1.79e+05
INCENDIO20  -23.5692    2.48e+05  -9.51e-05  1.000  -4.86e+05  4.86e+05
INCENDIO21  -22.8087    2.42e+05  -9.41e-05  1.000  -4.75e+05  4.75e+05
SEM_APP      0.4977     0.214    2.324  0.020    0.078    0.917
SEM_RL       0.4431     0.148    2.988  0.003    0.152    0.734
CAR          1.1902     0.149    7.980  0.000    0.898    1.483
=====
    
```

Figura 20. Resultado do modelo de regressão binomial dos fatores de risco de desmatamento para o ano de 2022

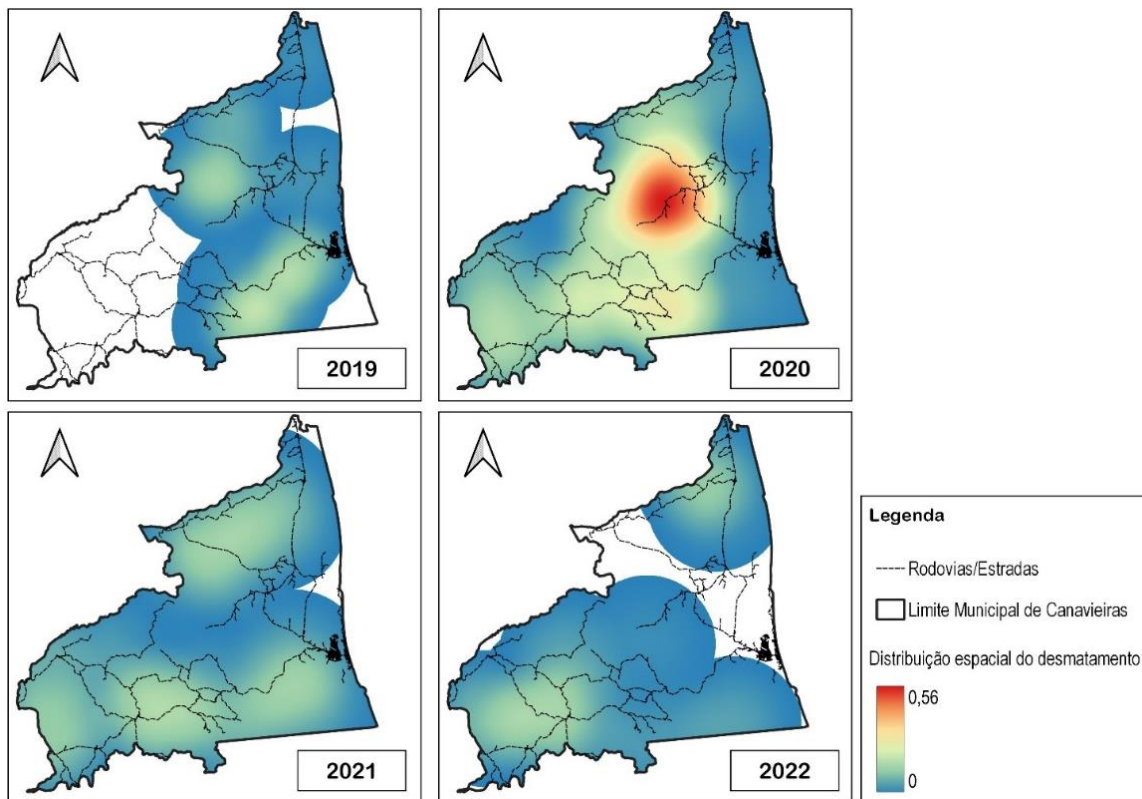
```

=====
Dep. Variable:      DESMATE_22  No. Observations:      98468
Model:              GLM        Df Residuals:          98449
Model Family:      Binomial    Df Model:              18
Link Function:     Logit       Scale:                 1.0000
Method:            IRLS       Log-Likelihood:        -1437.6
Date:              Fri, 18 Aug 2023  Deviance:              2875.2
Time:              02:33:50     Pearson chi2:          9.43e+04
No. Iterations:    26          Pseudo R-squ. (CS):    0.0005434
Covariance Type:   nonrobust

=====
              coef  std err      z  P>|z|    [0.025    0.975]
-----
Intercept    -6.7585    0.383   -17.660  0.000   -7.509   -6.008
DESMATE_19  -21.3285    4.76e+04  -0.000  1.000  -9.32e+04  9.32e+04
DESMATE_20  -21.6580    2.94e+04  -0.001  0.999  -5.77e+04  5.77e+04
DESMATE_21  -21.6242    3.43e+04  -0.001  0.999  -6.73e+04  6.73e+04
AGRICULTUR   1.9704     0.727    2.711  0.007    0.546    3.395
PASTAGEM     0.0447     0.149    0.300  0.764   -0.248    0.337
MOSAIC_USO   0.4557     0.145    3.133  0.002    0.171    0.741
AREA_URBAN  -20.8585    8.38e+04  -0.000  1.000  -1.64e+05  1.64e+05
SILVICULTU  -1.7854     1.005   -1.776  0.076   -3.756    0.185
RODOVIA     -0.5002     0.585   -0.856  0.392   -1.646    0.646
ASSE_RURAL   0.2098     0.367    0.572  0.567   -0.509    0.929
DECLIVIDAD  -0.4675     0.173   -2.701  0.007   -0.807   -0.128
INCENDIO19  -21.1527    3.44e+04  -0.001  1.000  -6.74e+04  6.74e+04
INCENDIO20  -21.2985    9.45e+04  -0.000  1.000  -1.85e+05  1.85e+05
INCENDIO21  -21.1610    9.06e+04  -0.000  1.000  -1.78e+05  1.78e+05
INCENDIO22  -20.9204    3.69e+04  -0.001  1.000  -7.22e+04  7.22e+04
SEM_APP      0.6600     0.285    2.318  0.020    0.102    1.218
SEM_RL      -0.1046     0.176   -0.594  0.552   -0.450    0.240
CAR          0.4571     0.172    2.664  0.008    0.121    0.793
=====
    
```

APÊNDICE IV

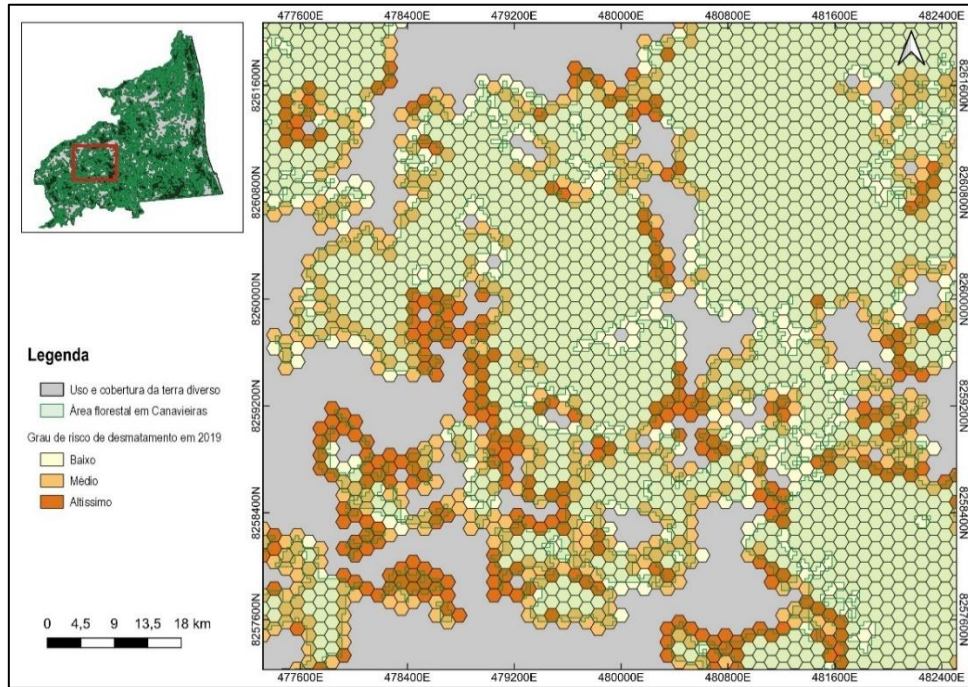
Figura 21. Distribuição espacial dos alertas de desmatamento ocorridos em Canavieiras entre 2019 e 2022 utilizando-se o EDK⁷



⁷ Para a obtenção dos raios de influência dos alertas de desmatamento do ano de 2019 a 2022, foi utilizado o estudo desenvolvido por Rizzatti *et al.* (2020). Conforme metodologia adotada pelos autores, os raios obtidos foram: $R_{2019} = 7,6$ km, $R_{2020} = 10,2$ km, $R_{2021} = 10,4$ km e $R_{2022} = 9,66$ km

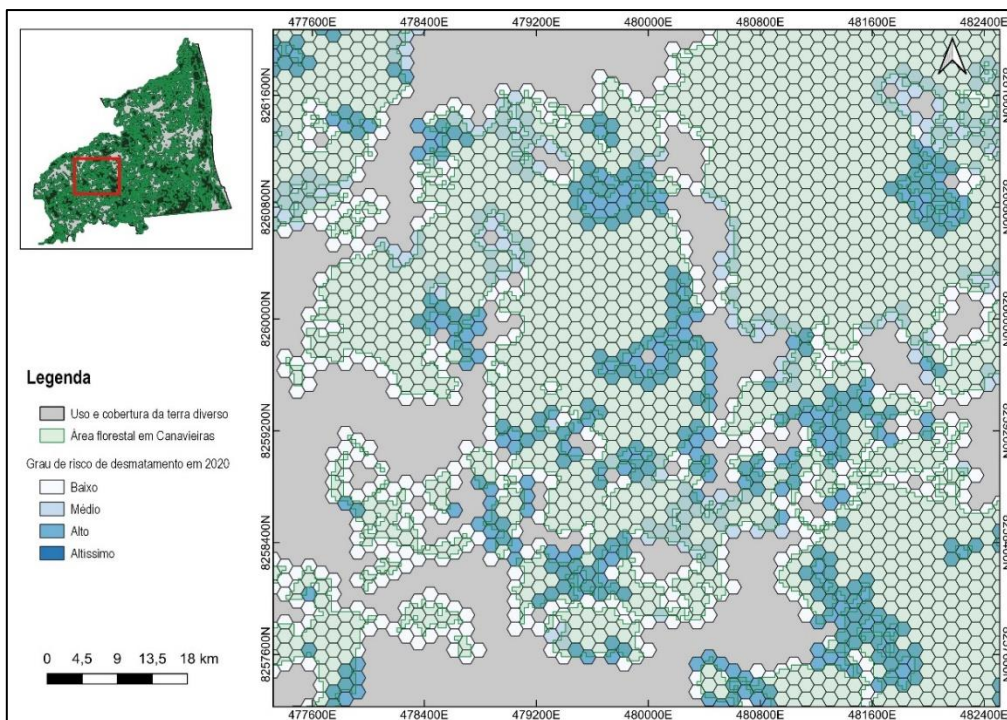
APÊNDICE V

Figura 22. Classificação das células do grid conforme o grau de risco para o ano de 2019 no município de Canaveira/BA



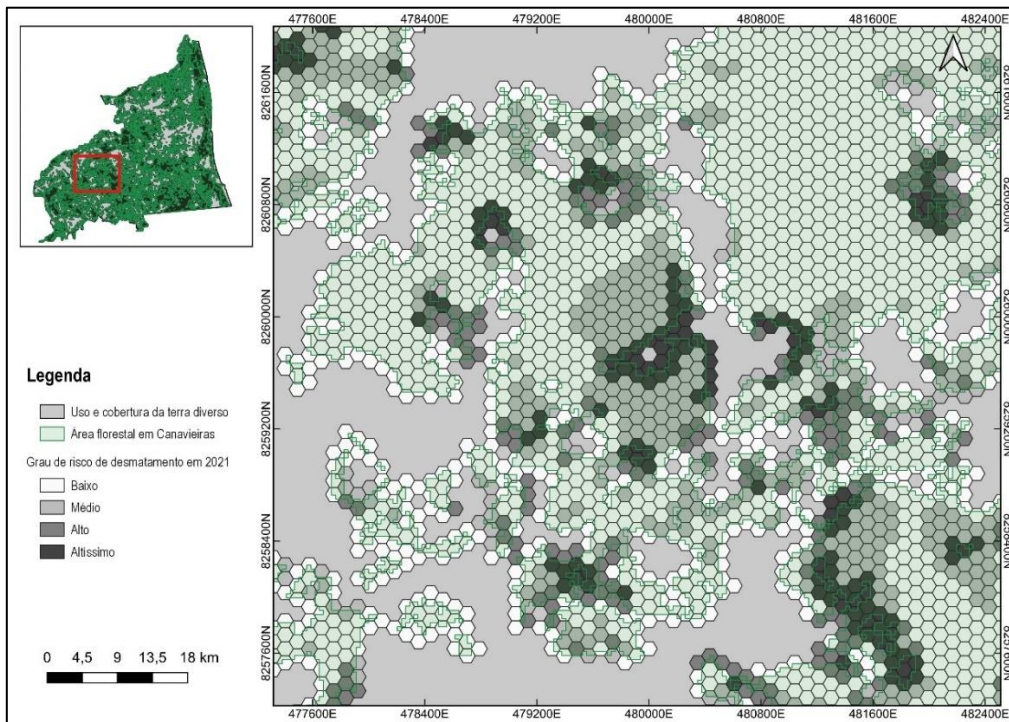
Fonte: Próprio autor, 2022

Figura 23. Classificação das células do grid conforme o grau de risco para o ano de 2020 no município de Canaveira/BA



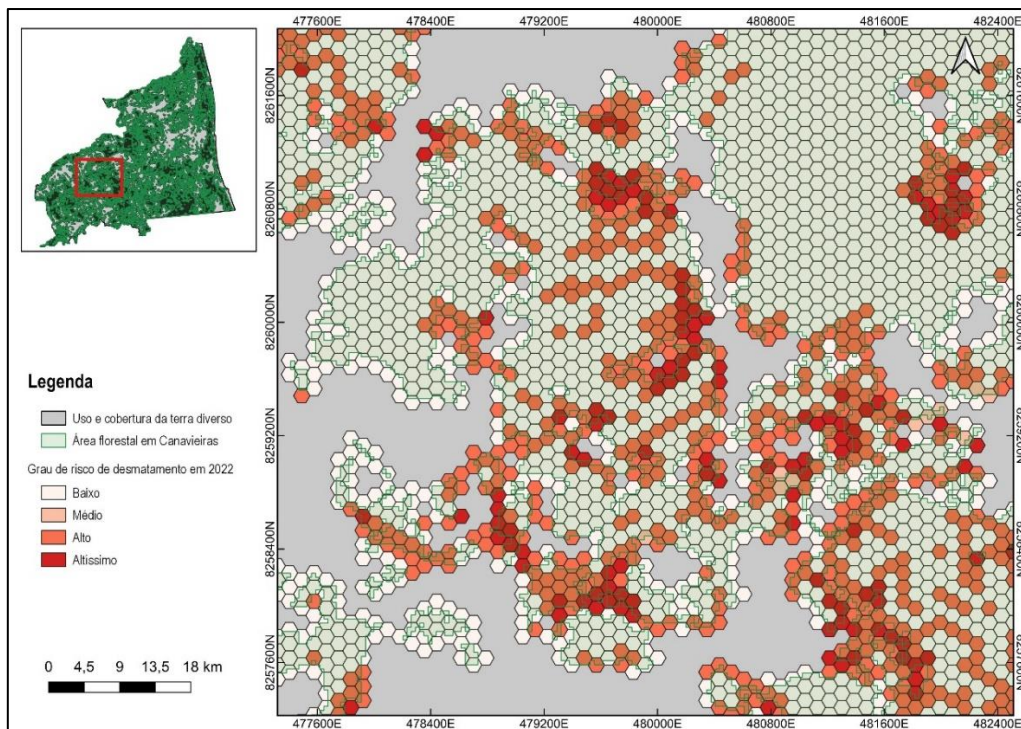
Fonte: Próprio autor, 2022

Figura 24. Classificação das células do grid conforme o grau de risco para o ano de 2021 no município de Canaveira/BA



Fonte: Próprio autor, 2022

Figura 25. Classificação das células do grid conforme o grau de risco para o ano de 2022 no município de Canaveira/BA



Fonte: Próprio autor, 2022

APÊNDICE VI

1. Aplica as bibliotecas e pacotes descritos no Quadro 6

```
import numpy as np -
import pandas as pd
from scipy.stats import poisson
import statsmodels.formula.api as smf
import statsmodels.api as sm
import matplotlib.pyplot as plt
```

2. Importa a planilha para o *Google Colab*

```
base = pd.read_excel('localizacao_do_arquivo')8
base.info() - # solicitando informações para verificação dos dados, ressalta-se que estes são
compostos por números inteiros. É importante destacar que a planilha deve conter apenas valores
0 ou 1
```

3. Analisa os dados por meio da Regressão Binomial

```
modRTM = smf.glm(formula = "VARIABEL_RESPOSTA9 ~ VARIABEL_1 + VARIABEL_2 +
VARIABEL_3 + ...", data=base, family=sm.families.Binomial()).fit()
print(modRTM.summary()) #mostrar resultados na tela
print(modRTM.aic) #mostrar resultados na tela para AIC
print(modRTM.bic) #mostrar resultados na tela para BIC
```

⁸ O arquivo deve estar salvo em uma pasta do *Google Drive* para que a planilha possa ser devidamente utilizada no *Google Colab*;

⁹ A coluna correspondente à variável de interesse deve ser separada das variáveis independentes para realizar a análise. Neste trabalho, a *variavel_resposta* foi representada pela coluna contendo as células do grid que interceptavam os alertas de desmatamento (cada célula que fazia interseção com os alertas recebia o valor 1). Já as demais variáveis, como pastagem e rodovias, foram consideradas variáveis independentes. Todo esse processo visou verificar se as variáveis independentes apresentavam alguma relação com a variável resposta, com base na análise de regressão binomial.