



UNIVERSIDADE FEDERAL DO CEARÁ
CENTRO DE CIÊNCIAS
DEPARTAMENTO DE GEOGRAFIA
PROGRAMA DE PÓS-GRADUAÇÃO EM GEOGRAFIA

ANDRÉA KARLA GOUVEIA CAVALCANTI

MODELOS PREDITIVOS DE USO E COBERTURA DA TERRA NA SUB-BACIA
HIDROGRÁFICA DO RIO BANABUIÚ

FORTALEZA
2025

ANDRÉA KARLA GOUVEIA CAVALCANTI

MODELOS PREDITIVOS DE USO E COBERTURA DA TERRA NA SUB-BACIA
HIDROGRÁFICA DO RIO BANABUIÚ

Tese apresentada ao Programa de Pós-Graduação em Geografia da Universidade Federal do Ceará como requisito à obtenção do título de Doutora em Geografia. Área de concentração: Dinâmica territorial e ambiental.

Orientador: Prof. Dr. Jader de Oliveira Santos.

FORTALEZA

2025

Dados Internacionais de Catalogação na Publicação
Universidade Federal do Ceará
Sistema de Bibliotecas

Gerada automaticamente pelo módulo Catalog, mediante os dados fornecidos pelo(a) autor(a)

- C385m Cavalcanti, Andréa Karla Gouveia.
Modelos Preditivos de Uso e Cobertura da Terra na Sub-bacia Hidrográfica do rio
Banabuiú / Andréa Karla Gouveia Cavalcanti. – 2025.
106 f. : il. color.
- Tese (doutorado) – Universidade Federal do Ceará, Centro de Ciências, Programa de
Pós-Graduação em Geografia, Fortaleza, 2025.
Orientação: Prof. Dr. Jader de Oliveira Santos.
1. Uso e cobertura da terra. 2. Bioma Caatinga. 3. Modelagem Preditiva. 4. Bacias
hidrográficas.. I. Título.

CDD 910

ANDRÉA KARLA GOUVEIA CAVALCANTI

MODELOS PREDITIVOS DE USO E COBERTURA DA TERRA NA SUB-BACIA
HIDROGRÁFICA DO RIO BANABUIÚ

Tese apresentada ao Programa de Pós-Graduação em Geografia da Universidade Federal do Ceará como requisito à obtenção do título de Doutora em Geografia. Área de concentração: Dinâmica territorial e ambiental.

Aprovada em: 28/08/2025

BANCA EXAMINADORA

Prof. Dr. Jader de Oliveira Santos (Orientador)
Universidade Federal do Ceará (UFC)

Prof. Dr. Vitor Matheus Bacani (Examinador Externo)
Universidade Federal de Mato Grosso do Sul (UFMS)

Prof. Dr. Silvio Braz de Sousa (Examinador Externo)
Universidade Federal do Rio Grande do Norte (UFRN)

Prof. Dr. Luís Gustavo de Lima Sales (Examinador Externo)
Universidade Federal de Campina Grande (UFCG)

Prof. Dr. Wallason Farias de Souza (Examinador Externo)
Universidade Estadual do Ceará (UECE)

A Deus.

Aos meus pais, Guilherme (*in memoriam*)
e Ione, por todo amor, suporte e estímulo
em toda a minha vida e trajetória
acadêmica.

AGRADECIMENTOS

A Deus, pelo dom da vida e por todas as graças alcançadas na minha.

Ao meu orientador Prof. Dr. Jader Santos, por toda a paciência, estímulo e conhecimento compartilhado.

A minha família, em especial aos meus pais, Guilherme (*in memoriam*) e Ione, e aos meus irmãos, Débora e Thompson, por todo amor, cuidado, carinho e incentivo ao longo da vida.

Ao meu esposo, André Pires, por todo amor, paciência, companheirismo e parceria na construção desse trabalho comigo.

Aos meus companheiros de Labocart, em especial Débora, Guitte, Teh, Felipe, Geovânia, Fabryna e Thiago. Vocês tornaram os meus dias mais leves dentro do Laboratório. As minhas amigas Silvia, Simone, Rutt e Raquel, colegas do doutorado.

Aos professores do Programa de Pós-Graduação em Geografia, por todo o conhecimento compartilhado com os alunos nas disciplinas do curso.

Ao Laboratório de Geoprocessamento, vinculado à Unidade Acadêmica de Ciências e Tecnologia Ambiental no Centro de Ciências e Tecnologia Agroalimentar (CCTA/UFCG), representado aqui pelo meu coordenador de laboratório, Gustavo Sales. Eu só consegui chegar até aqui graças à experiência profissional obtida nesse ambiente.

Aos meus colegas de trabalho no Centro de Ciências e Tecnologia Agroalimentar. Sem o apoio, o suporte acadêmico e psicológico que vocês me ofereceram desde o início nada disso seria possível.

À Universidade Federal de Campina Grande pelo apoio financeiro concedido.

Aos secretários da Pós-Graduação em Geografia, Edilene e Erandir, por todo apoio prestado ao longo do curso

À banca examinadora por aceitarem o convite de colaborar com essa pesquisa.

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

RESUMO

As mudanças climáticas, o avanço da agropecuária, a retirada da vegetação nativa, a emissão de poluentes atmosféricos e o despejo de efluentes domésticos e industriais nos recursos hídricos são alguns dos fatores que estão relacionados às principais causas dessa deterioração. Nessa lógica, a observação contínua da paisagem e o entendimento de sua evolução são essenciais para o controle da degradação, uma vez que as alterações da paisagem são consequências da pressão humana. Assim, observou-se que a problemática dos impactos ambientais causados pela mudança na paisagem tem como exemplo a sub-bacia hidrográfica do rio Banabuiú, no Ceará, escolhida como área de estudo deste trabalho. Essa área de captação pertence à bacia hidrográfica do rio Jaguaribe e está situada no Sertão Central Cearense com sua extensão totalmente inserida no semiárido. Os modelos preditivos de uso e cobertura da terra auxiliam na compreensão da dinâmica das mudanças ao longo do tempo e permitem o planejamento de ações de prevenção de impactos ambientais considerando cenários futuros. Optou-se nessa pesquisa pelo uso do modelo preditivo de Markov associado com métodos de Autômatos Celulares implementados no software Patch-generation Land Use Simulation (PLUS) Model V1.4. Sendo assim, com a pretensão em contribuir com projetos de conservação e preservação dos recursos naturais na sub-bacia hidrográfica do rio Banabuiú, essa pesquisa avaliou a viabilidade de uso do modelo preditivo da Cadeia de Markov junto aos Autômatos Celulares para analisar a dinâmica de mudanças do uso e cobertura da terra entre 2003 e 2022 na área de estudo. Como conclusões, essa pesquisa expõe as limitações técnicas da modelagem preditiva de uso e cobertura da terra em ambientes como o bioma da Caatinga, presente na sub-bacia hidrográfica do rio Banabuiú. O aspecto caducifólio da vegetação da Caatinga foi o principal fator de dificuldade para a modelagem da cobertura vegetal, uma vez que essa característica produz falsos alarmes com relação ao desmatamento, não sendo possível realizar as predições.

Palavras-chave: Uso e cobertura da terra; bioma Caatinga; modelagem preditiva; bacias hidrográficas.

RÉSUMÉ

Le changement climatique, l'expansion de l'agriculture, la disparition de la végétation indigène, l'émission de polluants atmosphériques et le rejet d'effluents domestiques et industriels dans les ressources en eau sont quelques-uns des facteurs associés aux principales causes de cette dégradation. Dans ce contexte, l'observation continue du paysage et la compréhension de son évolution sont essentielles pour contrôler la dégradation, car les changements paysagers sont les conséquences de la pression humaine. Ainsi, le sous-bassin du fleuve Banabuiú, au Ceará, choisi comme zone d'étude pour cette étude, illustre bien la problématique des impacts environnementaux causés par les changements paysagers. Ce bassin versant appartient au bassin du fleuve Jaguaribe et se situe dans la région du Sertão Central du Ceará, avec toute son étendue en zone semi-aride. Les modèles prédictifs d'utilisation et d'occupation des sols aident à comprendre la dynamique des changements au fil du temps et permettent de planifier des actions pour prévenir les impacts environnementaux, en tenant compte des scénarios futurs. Cette recherche a utilisé un modèle prédictif de chaîne de Markov combiné à des méthodes d'automates cellulaires implémentées dans le logiciel Patch-generation Land Use Simulation (PLUS) Model V1.4. Par conséquent, dans le but de contribuer aux projets de conservation et de préservation des ressources naturelles dans le sous-bassin du fleuve Banabuiú, cette étude a évalué la faisabilité de l'utilisation du modèle prédictif de chaîne de Markov en conjonction avec des automates cellulaires pour analyser la dynamique de l'utilisation et de l'évolution de la couverture terrestre entre 2003 et 2022 dans la zone d'étude. En conclusion, cette recherche met en évidence les limites techniques de la modélisation prédictive de l'utilisation et de la couverture terrestre dans des environnements tels que le biome de la Caatinga, présent dans le sous-bassin du fleuve Banabuiú. La nature caduque de la végétation de la Caatinga a été la principale difficulté de la modélisation de la couverture terrestre, car cette caractéristique produit de fausses alertes concernant la déforestation, rendant les prévisions impossibles.

Mots-clés: Utilisation et couverture des terres; biome de la caatinga; modélisation prédictive; bassins versants.

ABSTRACT

Climate change, the expansion of agriculture, the removal of native vegetation, the emission of atmospheric pollutants, and the discharge of domestic and industrial effluents into water resources are some of the factors associated with the main causes of this deterioration. In this context, continuous observation of the landscape and understanding its evolution are essential for controlling degradation, since landscape changes are consequences of human pressure. Thus, the problem of environmental impacts caused by landscape change is exemplified by the Banabuiú River sub-basin in Ceará, chosen as the study area for this study. This catchment area belongs to the Jaguaribe River basin and is located in the Sertão Central region of Ceará, with its entire extent within the semiarid region. Predictive land use and land cover models help understand the dynamics of changes over time and enable the planning of actions to prevent environmental impacts, considering future scenarios. This research used a predictive Markov chain model combined with cellular automata methods implemented in the Patch-generation Land Use Simulation (PLUS) Model V1.4 software. Therefore, with the aim of contributing to natural resource conservation and preservation projects in the Banabuiú River sub-basin, this study evaluated the feasibility of using the predictive Markov chain model in conjunction with cellular automata to analyze the dynamics of land use and land cover change between 2003 and 2022 in the study area. In conclusion, this research highlights the technical limitations of predictive land use and land cover modeling in environments such as the Caatinga biome, present in the Banabuiú River sub-basin. The deciduous nature of the Caatinga vegetation was the main difficulty in modeling land cover, as this characteristic produces false alarms regarding deforestation, making predictions impossible.

Keywords: Land use and land cover; caatinga biome; predictive modeling; watersheds.

LISTA DE FIGURAS

Figura 1 - Etapas da análise bibliométrica.	34
Figura 2 - Distribuição de estudos globais sobre LULC e CA-Markov.	37
Figura 3 - Nuvem de palavras relacionadas com a Cadeia de Markov.	39
Figura 4 - Palavras de frequência nas publicações científicas sobre CA-Markov.	39
Figura 5 - Mapa de localização da sub-bacia hidrográfica do rio Banabuiú.	43
Figura 6 - Curva hipsométrica da sub-bacia hidrográfica do rio Banabuiú.	45
Figura 7 - Mapa geológico da sub-bacia hidrográfica do rio Banabuiú.	48
Figura 8 - Mapa pedológico da sub-bacia hidrográfica do rio Banabuiú.	49
Figura 9 - Mapa geomorfológico da sub-bacia hidrográfica do rio Banabuiú.	50
Figura 10 - Uso e cobertura da terra da sub-bacia hidrográfica do rio Banabuiú.	51
Figura 11 - Estrutura de uma Rede Neural Artificial Multi Layer Perceptron com 4 entradas, 10 neurônios na camada oculta e 5 outputs (saídas).	57
Figura 12 - Mapas de uso e cobertura da terra para os anos de 2003, 2014 e 2022.	64
Figura 13 - Açude da Cachoeira do Germano, Vale do Forquilha, Quixeramobim, Ceará (02/05/2014).	67
Figura 14 - Afloramento Rochoso em Quixeramobim (01/05/2024).	68
Figura 15 - Reconhecimento de campo no Perímetro Irrigado de Morada Nova (07/09/2023).	69
Figura 16 - Cultivo de milho em Quixeramobim (02/05/2023).	70
Figura 17 - Registro de campo no Açude Banabuiú (08/09/2023).	70
Figura 18 - Visitas de campo no Açude de Quixeramobim realizadas no dia 08/09/2023 e 01/05/2023.	71
Figura 19 - Áreas de pasto próximas a pequenos açudes (02/05/2023).	72
Figura 20 - Mapas de uso e cobertura da terra da sub-bacia hidrográfica do rio Banabuiú (2003, 2014 e 2022).	80
Figura 21 - Mapa de expansão da terra (2003 – 2022).	81
Figura 22 - Mapas de desenvolvimento potencial para cada classe de uso e cobertura da terra 2003 – 2022.	83
Figura 23 - Mapa de Uso e Cobertura da Terra simulado (2022) X Uso e Cobertura da Terra (2022).	86
Figura 24 - Mapa simulado com a Cadeia de Markov.	89

LISTA DE QUADROS

Quadro 1 - Principais informações bibliométricas.	34
Quadro 2 - Principais autores na área do conhecimento da CA-Markov e LULC.....	38
Quadro 3 - Dados climatológicos na sub-bacia hidrográfica do rio Banabuiú (1974 a 2016)	46
Quadro 4 - Características das imagens adquiridas.....	56
Quadro 5 - Chave de interpretação.	57
Quadro 6 - Configuração dos parâmetros no módulo CARS.....	84
Quadro 7- Matriz de Transição das classes de uso e cobertura da terra.	85

LISTA DE TABELAS

Tabela 1 - Classes de declividade observadas na área de estudo.....	45
Tabela 2 - População, PIB e IDHM dos municípios presentes na sub-bacia hidrográfica do rio Banabuiú.	52
Tabela 3 - Definições e resultados da RNA para os usos e coberturas da terra em 2003, 2014 e 2022.	59
Tabela 4 - Matriz de erros de confusão no mapa classificado de 2003 (amostras de teste).	60
Tabela 5 - Matriz de erros de confusão no mapa classificado de 2014 (amostras de teste).)	61
Tabela 6 - Matriz de erros de confusão no mapa classificado de 2022 (amostras de teste).	62
Tabela 7 - Quantitativo de áreas e porcentagem de cada classe de uso e cobertura da terra.	64
Tabela 8 - Índice pluviométrico entre Janeiro e Maio nos anos de 2003, 2014 e 2022.	66
Tabela 9 - Contribuição dos fatores de força na escala de tempo (2003-2022).	82
Tabela 10 - Land Use Demand (2022).	84
Tabela 11 - <i>Neighborhood Weights</i> (2003 - 2022).	85
Tabela 12 - Diferença entre os cenários simulados e o dado real observado.	87
Tabela 13 - Métricas de avaliação para o cenário 2003-2022.	87
Tabela 14 - Comparação entre o modelo produzido pelo método CARS e a Cadeia de Markov.	89

LISTA DE GRÁFICOS

Gráfico 1 - Produção científica anual sobre modelos preditivos em sensoriamento remoto	29
Gráfico 2 - Produção científica anual com as palavras-chave CA-Markov e LULC...	35
Gráfico 3 - Produção dos países ao longo do tempo.	36
Gráfico 4 - Produtividade dos autores através da Lei de Lotka.	38
Gráfico 5 - Distribuição percentual das classes de uso e cobertura da terra.	65

LISTA DE ABREVIATURAS E SIGLAS

APP	Área de Preservação Permanente
COGERH	Companhia de Gestão dos Recursos Hídricos do Ceará
DPSIR	Drive Forces – State – Pressure – Impact – Response
EEA	European Environment Agency
FPEIR	Força – Estado – Pressão – Estado – Impacto - Resposta
FUNCEME	Fundação Cearense de Meteorologia e Recursos Hídricos
IBGE	Instituto Brasileiro de Geografia e Estatística
OECD	Organização para a Cooperação e Desenvolvimento Econômico
OLI	Operational Land Imager
ONU	Organização das Nações Unidas
PER	Pressão – Estado – Resposta
RPAS	Remotely Piloted Aircraft System
TM	Thematic Mapper

SUMÁRIO

1	INTRODUÇÃO	18
1.1	Objetivos	21
1.2	Metodologia	22
1.3	Organização da tese	23
2	MODELOS PREDITIVOS DE USO E COBERTURA DA TERRA E CADEIA DE MARKOV	24
2.1	Introdução	24
2.2	Modelos preditivos	25
2.3	Modelos preditivos no sensoriamento remoto	28
2.3.1	<i>Cadeia de Markov e CA-Markov na predição do uso e cobertura da terra</i>	31
2.3.2	<i>Análise Bibliométrica</i>	33
2.4	Considerações finais	40
3	CARACTERIZAÇÃO AMBIENTAL DA ÁREA DE ESTUDO	41
3.1	Introdução	41
3.2	Localização	42
3.3	Procedimentos metodológicos	43
3.4	Aspectos fisiográficos	44
3.4.1	<i>Recursos hídricos e Hipsometria</i>	44
3.4.2	<i>Clima</i>	46
3.4.3	<i>Geologia</i>	47
3.4.4	<i>Pedologia</i>	48
3.4.5	<i>Geomorfologia</i>	49
3.4.6	<i>Uso e cobertura da terra</i>	50
3.4.7	<i>Aspectos socioeconômicos</i>	51
3.5	Considerações finais	53
4	ANÁLISE TEMPORAL DO USO E COBERTURA DA TERRA	54
4.1	Introdução	54
4.2	Procedimentos metodológicos de análise temporal	55
4.2.1	<i>Pré-processamento</i>	56

4.2.2	Processamento	56
4.2.3	Pós-processamento	59
4.3	Resultados e discussões de análise temporal	59
4.3.1	Avaliação da acurácia	59
4.3.2	Dinâmica de mudanças no uso e cobertura da terra na sub-bacia do rio Banabuiú (2003-2022)	63
4.4	Considerações finais	72
5	MODELAGEM DO USO E COBERTURA DA TERRA	74
5.1	Introdução	74
5.2	Procedimentos metodológicos	76
5.2.1	Classificação das imagens de satélite	76
5.2.2	Mapa de expansão da terra (Extract Land Expansion)	77
5.2.3	Definição dos fatores de força	77
5.2.4	Análise de estratégia de expansão da terra (Land Expansion Analysis Strategy – LEAS)	78
5.2.5	CA based on Multiple Random Seeds - CARS	78
5.2.6	Validação dos resultados (Validation)	79
5.2.7	Demand Prediction	79
5.3	Resultados e discussões	79
5.3.1	Mapas de Expansão da Terra	79
5.3.2	Definição dos fatores de força	81
5.3.3	Análise de Estratégia de Expansão da Terra (Land Expansion Analysis Strategy – LEAS)	83
5.3.4	CA based on Multiple Random Seeds – CARS	84
5.3.5	Validação dos resultados (Validation)	86
5.3.6	Demand Prediction	88
5.4	Considerações finais	90
6	CONSIDERAÇÕES FINAIS	92
	REFERÊNCIAS	94

1 INTRODUÇÃO

A *Política Nacional do Meio Ambiente* (Brasil, 1981) conceitua a degradação da qualidade ambiental como sendo uma “alteração adversa da qualidade do meio ambiente” (BRASIL, 1981, Art. 3, inciso III) e entende-se que ela pode ocorrer por fatores naturais, como as enchentes e a escassez hídrica, o que, por consequência do agravamento das mudanças climáticas, vêm se tornando cada vez mais graves e frequentes.

Por outro lado, o processo de degradação pode ocorrer igualmente por causas antrópicas, por meio da supressão da vegetação, da emissão de poluentes atmosféricos, do despejo de efluentes domésticos e industriais nos corpos hídricos, do lançamento de agrotóxicos no cultivo agrícola, entre outros. No Nordeste brasileiro, por exemplo, a retirada de vegetação nativa e as queimadas estão entre os principais fatores prejudiciais ao meio ambiente provocados pelo ser humano (Silva *et al.*, 2018).

Alguns dos dados que chamam atenção sobre esse tópico dizem respeito à Caatinga, predominante no semiárido da região Nordeste. Trata-se do bioma menos conhecido do país, apesar de ser considerado o bioma semiárido mais biodiverso do mundo. Dados do IBGE (2024) indicam que aproximadamente 80% dos ecossistemas originais já foram alterados majoritariamente por queimadas e desmatamentos e que 62% das áreas susceptíveis à desertificação estão em zonas originalmente ocupadas por caatinga.

As atividades antrópicas, as mudanças climáticas, a redução na pluviometria e a intensificação nos eventos de seca são alguns fatores que a tornam um ecossistema muito ameaçado e susceptível a desertificação (Jardim *et al.*, 2022). No entanto, mesmo neste contexto, a Caatinga atualmente possui apenas 9% de sua totalidade amparada por Unidades de Conservação (UCs), sendo pouco mais de 2% dessas UCs classificadas como Unidades de Proteção Integral, por IBGE (2024). Esses dados comprovam a necessidade de um monitoramento mais efetivo como medida preventiva contra a supressão da vegetação nativa na região. Segundo Conacher (1998), a observação contínua da paisagem é fundamental para o controle de áreas degradadas, uma vez que as mudanças ocorrentes no uso e cobertura da terra representam as consequências das pressões humanas. Em consonância com o que foi dito anteriormente, Arnous, El-Rayes e Helmy (2017) afirmam que a compreensão das alterações na paisagem é fundamental para a melhoria das

estratégias relacionadas aos impactos geoambientais. No que se refere às consequências que as modificações na paisagem podem provocar na sociedade, Chang *et al.* (2018) descrevem que essas alterações provocam impactos diretos sobre a qualidade de vida da população, principalmente no que diz respeito à segurança hídrica e alimentar.

Para Hassan *et al.* (2016), a velocidade com que ocorrem mudanças no uso e cobertura da terra está muito maior atualmente e essa taxa mais elevada, provocada por fatores em escala locais e globais, está causando alterações sem precedentes nos processos ecológicos e ambientais. Hoque *et al.* (2022) destacam a influência da dinâmica de uso e cobertura da terra sobre os serviços ecossistêmicos pois, segundo os autores, a alteração constante da paisagem aliada às variáveis climáticas pode provocar uma redução drástica nos recursos ecológicos, com impactos inclusive nos recursos hídricos.

Nesse panorama, adversidades dos impactos ambientais causados pela mudança na paisagem são observadas na sub-bacia hidrográfica do rio Banabuiú (CE). Tal área de captação pertence à bacia hidrográfica do rio Jaguaribe e está situada no Sertão Central Cearense com sua extensão totalmente inserida no semiárido. Silva e Mendes (2019) observaram uma predominância de áreas moderadamente susceptíveis à erosão laminar nessa região, enquanto Lima e Silva (2018) observaram, após a execução do mapa de vulnerabilidade natural, que os recursos hídricos da sub-bacia hidrográfica do rio Banabuiú são os mais susceptíveis aos riscos ambientais. Ao avaliar índices da dimensão ambiental na área de estudo, Silva e Lima (2017) indicaram que 92% dos municípios integrantes da região hidrográfica apresentaram desempenho sustentável, potencialmente sustentável e sustentabilidade média, o que foi considerado um resultado positivo, apesar da necessidade de melhoria em diversos indicadores.

A escala temporal adotada para a presente pesquisa, de 2003 a 2022, foi motivada pela possibilidade de visualizar espacialmente as consequências da escassez hídrica presente entre 2012 e 2016, a qual foi considerada pela Secretaria de Recursos Hídricos do Ceará a pior situação já enfrentada desde 1910 (Ceará, c2017). Dessa forma, foi possível perceber os efeitos das estratégias de convivência com a seca adotadas pela população local através das políticas públicas como a implantação de cisternas. Segundo Tritsch *et al.* (2023), os anos de seca trouxeram várias consequências drásticas para a área de estudo em várias atividades, como o

abastecimento de água para o consumo humano e a produção agrícola. Ao mesmo tempo em que a modificação da paisagem é consequência das pressões antrópicas sobre o meio ambiente, o monitoramento dessas alterações, de maneira a permitir um planejamento adequado do uso e da cobertura da terra, pode ser uma solução para a mitigação e a prevenção de impactos ambientais.

Os modelos preditivos de uso e cobertura da terra auxiliam na compreensão da dinâmica das mudanças existentes ao longo do tempo e permitem planejar ações de prevenção de impactos ambientais considerando cenários futuros. Os principais modelos preditivos utilizados para a análise de mudança na paisagem são os baseados em séries temporais, sendo eles os de Regressão, os de Redes Neurais Artificiais e os Híbridos de Autômatos Celulares, de acordo com Navin e Agilandeewari (2020). Trata-se de uma tecnologia que muito agrega à conjuntura atual, uma vez que a predição dos cenários futuros de uso e cobertura da terra pode utilizar, além das imagens multiespectrais originárias dos satélites de observação terrestre, outros fatores, como dados de declividade, elevação do terreno, distância euclidiana de variáveis – como a zona urbana –, corpos hídricos e zonas de agricultura. Isso permite uma avaliação do cenário de forma mais precisa, considerando os fatores modificadores da paisagem como sendo não apenas os naturais, mas também os de origem antrópica.

Durante a última década, algumas pesquisas foram desenvolvidas no ramo da evolução temporal, modelagem e predição do uso e cobertura da terra com metodologias e fins diversos. O método escolhido para ser estudado e aplicado nessa pesquisa é um modelo Híbrido de Autômatos Celulares combinado com a regressão logística da Cadeia de Markov (CA-Markov) que, segundo Cunha *et al.* (2021), permite alcançar resultados mais exatos com a junção das propriedades dos dois métodos. Para Alqadhi *et al.* (2021), o modelo de Markov utiliza uma matriz de probabilidade de transição entre as classes durante o intervalo de tempo adotado, enquanto os Autômatos Celulares estão incluídos em uma categoria de modelos dinâmicos preditivos que tem como principal vantagem a possibilidade de integração com outros modelos.

O modelo CA-Markov é bem aceito no ambiente acadêmico para a predição das mudanças do uso e ocupação da terra. Diversos autores, utilizados nas bases dessa pesquisa, provaram os benefícios do uso da Cadeia de Markov quando combinado com o uso dos Autômatos Celulares em estudos de uso e cobertura da

terra, sendo alguns deles: Liping, Yujun e Saeed (2018); Mandal, Ghosh e Mukhopadhyay, (2019); Akdeniz, Sag e Inam (2023); Wang *et al.* (2020); Odiji *et al.* (2022); Singh, Venkatramanan e Deshmukh (2022); Bakr, Morsy e Yehia (2022); Chim *et al.* (2019); Gao *et al.* (2021); Ansari e Golabi (2019); Roushangar *et al.* (2023); Sundar e Deka (2022) e Cunha *et al.* (2021).

Com essa pesquisa, pretendeu-se responder aos questionamentos sobre a viabilidade do uso do modelo de CA-Markov em ambientes semiáridos. Seria possível obter resultados com o modelo preditivo que correspondam à realidade? Se sim, o modelo obtido poderia ser utilizado como base para projetos de uso e de ocupação da terra que visem mitigar os impactos da degradação ambiental? O processo de ocupação do espaço na área de captação do rio Banabuiú durante as duas últimas décadas contribuiu para o estado de degradação na paisagem? A fim de responder essa e demais questões adjacentes, tornou-se possível delimitar objetivos e metodologias que respondessem a essas demandas.

1.1 Objetivos

Para responder as questões anteriores, a pesquisa foi estruturada de modo a atingir o objetivo principal de avaliar a viabilidade de uso do modelo preditivo da Cadeia de Markov junto aos Autômatos Celulares para analisar a dinâmica de mudanças do uso e cobertura da terra entre 2003 e 2022 na área de estudo. A fim de alcançar esse objetivo maior, elencou-se objetivos específicos. Inicialmente, notou-se a importância de (i) revisar de forma bibliográfica e bibliométrica o uso de modelos preditivos nos estudos de uso e cobertura da terra, para, em seguida, (ii) caracterizar ambientalmente a sub-bacia hidrográfica do rio Banabuiú considerando os aspectos fisiográficos e socioeconômicos. Na sequência, objetivou-se (iii) analisar a evolução espaço-temporal do uso e ocupação da terra na sub-bacia hidrográfica do rio Banabuiú durante o período compreendido entre 2003 a 2022 e, por fim, (iv) modelar e simular cenários futuros de uso e cobertura da terra durante o escopo temporal de 2003 a 2022 com base no método preditivo de Markov associado aos Autômatos Celulares. Espera-se que essa pesquisa possa contribuir como uma ferramenta mais efetiva para o acompanhamento da degradação ambiental através do monitoramento da cobertura vegetal, na sub-bacia hidrográfica do rio Banabuiú.

1.2 Metodologia

Os procedimentos metodológicos adotados nessa pesquisa se iniciam com a caracterização ambiental da área de estudo, que envolveu a coleta de dados geomorfológicos, pedológicos, geológicos, climatológicos, hidrológicos e socioeconômicos. Para isso, foi feita uma consulta bibliográfica do que já foi produzido na área estudada e um levantamento de dados cartográficos disponibilizados em plataformas governamentais, como o Instituto Brasileiro de Geografia e Estatística (IBGE), o Serviço Geológico do Brasil (SGB), a Plataforma Estadual de Dados Espaciais Ambientais do Ceará (PEDEA) e a Companhia de Gestão dos Recursos Hídricos do Ceará (Cogerh).

As informações de hipsometria utilizadas nessa pesquisa foram obtidas do Copernicus DEM, pertencente ao Programa de Observação da Terra da União Europeia, pois, segundo Bielski *et al.* (2024), o Modelo Digital de Elevação (MDE) desse instrumento se destaca com uma superioridade significativa em comparação com os outros cinco MDEs globais disponíveis atualmente. Foram obtidos produtos da categoria Digital Gridded Elevation Data (DGED) com valores decimais e resolução espacial de 30 metros.

A delimitação da sub-bacia hidrográfica do rio Banabuiú foi obtida no PEDEA-CE e os dados históricos referentes a pluviometria, balanço hídrico, índice de aridez e evapotranspiração de referência média anual correspondentes ao período de 1974 a 2016 foram adquiridos na Fundação Cearense de Meteorologia e Recursos Hídricos (Funceme, 2023). Os dados geológicos, pedológicos, geomorfológicos e de vegetação foram obtidos no *site* do IBGE na escala de 1:250.000. Os dois aspectos são referentes ao ano de 2021.

Para a execução da análise, foram realizados mapeamentos de uso e cobertura da terra em três datas distintas, referente aos anos de 2003, 2014 e 2022. As imagens foram obtidas dos sensores TM e OLI pertencentes, respectivamente, aos satélites Landsat 5, 8 e 9. O algoritmo utilizado para o reconhecimento de padrões das imagens foi o Backpropagation, implementado no *software* Matlab, sendo a imagem mais recente validada com dados de campo. A última fase da incluiu a análise de viabilidade do modelo de Markov com a modelagem dos mapas de uso e cobertura da terra de 2003 e 2014 e predição do mapa de 2022 para a checagem dos resultados no *software* Patch-generation Land Use Simulation (PLUS) Model V1.4. Uma vez que

a resposta da modelagem fosse considerada positiva, seriam gerados cenários futuros de uso e cobertura da terra para a sub-bacia hidrográfica do rio Banabuiú.

1.3 Organização da tese

A tese está estruturada em cinco capítulos, organizados em artigos. O primeiro capítulo é a introdução contendo a problemática, a justificativa e os objetivos. O segundo engloba a fundamentação teórico-metodológica com um estado da arte e uma análise bibliométrica sobre o modelo preditivo da Cadeia de Markov. O terceiro compreende à caracterização ambiental da área de estudo. O quarto capítulo contém a dinâmica da evolução temporal das mudanças de uso e cobertura da terra observadas na sub-bacia hidrográfica do rio Banabuiú. O quinto capítulo abrange a análise da viabilidade de uso do modelo de Markov na modelagem do uso e cobertura da terra na área de estudo.

2 MODELOS PREDITIVOS DE USO E COBERTURA DA TERRA

2.1 Introdução

A análise preditiva utiliza como base métodos estatísticos e/ou técnicas de mineração de dados (Kumar; Grag, 2018; Waljee; Higgins; Singal, 2014). A modelagem preditiva, segundo Kumar e Grag (2018), é uma etapa do Processo Analítico Preditivo que inclui também as fases da coleta, manipulação de dados, predição e monitoramento dos resultados. A fase do modelo de predição permite identificar, com base em dados históricos, padrões que descrevem o comportamento de determinadas variáveis, a fim de prever cenários futuros. A complexidade desse tipo de modelo é diretamente proporcional à quantidade de dados coletados e ao número de parâmetros utilizados na calibração (Biecek, 2018).

A metodologia preditiva pode ser aplicada em diversas áreas do conhecimento, como a medicina, a economia, a epidemiologia, a demografia, o marketing e, mais recentemente, a análise de dados geográficos. Na área de conhecimento do Sensoriamento Remoto, por exemplo, o uso de modelos preditivos de uso e cobertura da terra vem sendo cada vez mais difundido pela possibilidade de auxiliar as estratégias de gestão no planejamento ambiental. A inclusão de fatores externos dos tipos físicos e socioeconômicos na análise também é um ponto positivo para o uso da inteligência artificial nesse ramo de aprendizado.

A escolha do modelo mais adequado ao conjunto de dados utilizado é um passo importante na modelagem preditiva. Alguns dos principais modelos utilizados na literatura científica são: Baseado em Agentes, Regressão Estatística, Dinâmica de Sistemas, Baseado em Regras, CA-Markov e Random Forest, por exemplo. Nesse trabalho, optou-se pelo uso dos Autômatos Celulares associado com a Cadeia de Markov.

Os Autômatos Celulares (CA) são comumente usados na predição das mudanças do uso e da cobertura da terra e, segundo Aburas, Ahamad e Omar (2019), possuem como principais vantagens a sua simplicidade, sua possibilidade de integração com outros modelos e sua facilidade de compreensão. Os Híbridos de Autômatos Celulares surgem a partir da necessidade de integração com outras

ferramentas e permitem uma maior acurácia ao adicionar variáveis externas ao modelo, como os modelos de elevação do terreno, a declividade, e fatores socioeconômicos, como a distância da mancha urbana. Entre os modelos que podem ser unidos aos Autômatos Celulares, pode-se citar as Redes Neurais Artificiais, o Processo Analítico Hierárquico, os modelos Multi-Layer (ML) *Support Vector Machine* e os modelos baseados no método da regressão logística.

Tratando-se das combinações utilizadas para a predição do uso e cobertura da terra, os Autômatos Celulares aliados à Cadeia de Markov (CA-Markov) se apresentam entre as principais opções. Trabalhos como os desenvolvidos por Cunha *et al.* (2021); Permatasari *et al.* (2021); Khan, Saeed e Bazai (2020); Khawaldah, Farhan e Alzboun (2020); Maurya, Rafi e Shamoo (2023); Aniah *et al.* (2023); Abijith e Saravanan (2022); Khwarahm *et al.* (2021); Mathanraj, Rusli e Ling (2021); Michel *et al.* (2021); Karimi *et al.* (2018); Floreano e Moraes (2021); Santos *et al.* (2024); Bacani *et al.* (2024); Fernandes *et al.* (2020); Cunha *et al.* (2021) e Feitosa *et al.* (2023) são apenas alguns exemplos dos estudos desenvolvidos com a CA-Markov nos últimos cinco anos.

Para compreender as potencialidades e os desafios ao utilizar modelos preditivos como o modelo híbrido CA-Markov no sensoriamento remoto, especialmente em estudos de uso e cobertura da terra, esse capítulo objetiva trazer um estado da arte com uma análise bibliográfica e bibliométrica a respeito dos modelos preditivos.

2.2 Modelos preditivos

As ferramentas de suporte à decisão surgiram como uma forma de auxiliar a humanidade na solução de incertezas inerentes em diversas áreas de conhecimento, como a economia, a medicina e os estudos acerca das mudanças climáticas. O avanço computacional, vivenciado a partir do fim do século XX e início do século XXI, agregou inovação ao Processo de Tomada de Decisão com a inclusão de algoritmos de Aprendizado de Máquina (Rautenberg; Carmo, 2019). É nesse momento que surgem os modelos, ou *model-based*, que são uma importante categoria das técnicas de suporte à decisão (Kwakkel; Walker; Marchau, 2010).

Kumar e Garg (2018) afirmam que os modelos presentes nas Técnicas de Análise Preditiva são capazes de prever cenários futuros com base em dados atuais

e históricos e os modelos são subdivididos em preditivos, descritivos e de decisão. Segundo Derry, Krzywinski e Altman (2023), os modelos preditivos são usualmente conhecidos por serem sistemas complexos e se caracterizam por possuírem parâmetros e saídas preditas, sendo que apenas a saída tem significado físico.

Como dito anteriormente, entre os tipos de métodos utilizados nos modelos preditivos estão as (i) Redes Neurais Artificiais (RNA), (ii) os Baseados em Agentes, (iii) de Regressão Estatística, (iv) os de Dinâmica de Sistemas, (v) Baseados em Regras, (vi) Random Forest e (vii) CA-Markov, os quais serão destrinchados a seguir.

A concepção das (i) RNAs se baseia no funcionamento do neurônio biológico, que é considerado um dispositivo computacional elementar com muitas entradas e uma saída (KÓVACS, 2006). O primeiro modelo computacional proposto com base no modelo biológico foi McCulloch e Pitts (1990), e, de acordo com Fleck et. al (2016), as RNAs se destacam enquanto modelo pela sua capacidade de aprendizagem na tomada de decisão. Os modelos baseados em RNA se subdividem em Back Propagation Neural Network, Recurrent Neural Network, Conventional Neural Network e Long Short Term Memory Neural (Navin e Agilandeeswari, 2020).

Tratando-se do (ii) modelo preditivo Baseado em Agentes, trata-se de um modelo que trabalha autonomamente com base em dados anteriores para cumprir um propósito específico (Bhargava; Poonia; Arora; 2016). Ainda segundo os autores citados anteriormente, os modelos Baseados em Agentes são sensíveis às mudanças no meio ambiente, além de possuírem capacidade de adaptação e de customização. Essa classe de modelo tem sido aplicada na avaliação de políticas públicas de segurança (Santos Filho, 2024), na área da saúde – como na simulação da adesão ao rastreio da retinopatia diabética (Pereira et. al, 2023) –, e na gestão empresarial (Fonseca; Ramos; Silva, 2016).

No que se refere aos (iii) modelos de predição de Regressão Estatística, esses são muito utilizados na simulação de cenários futuros e surgiram a partir da influência da aprendizagem de máquinas na comunidade estatística, sendo o *regression tree* (Morgan; Sonquist, 1963) o primeiro modelo criado com esse fim (Özkale, 2015). Fazem parte dessa categoria os modelos de Regressão Linear e os de Regressão Logística, como a Cadeia de Markov, que foi desenvolvida por Andrei Andreyevich Markov em 1907. Ela tem como principais áreas de atuação em que é empregada com eficácia a Teoria dos Jogos, com o problema da “ruína do jogador”; a modelagem matemática do comportamento de filas, chamada de teoria de filas; a

epidemiologia; os processos migratórios e o sensoriamento remoto (Júnior; Júnior, 2011). Essa ferramenta metodológica possui grande utilidade na predição de uso e cobertura da terra (Aniah *et al.*, 2023; Cunha *et al.*, 2021; Floreano; Moraes, 2021; Khawaldah; Farhan; Alzboun, 2020; Maurya; Rafi; Shamoo, 2023) e tem a habilidade de converter uma amostra de um estado para outro por meio de uma matriz de probabilidade de transição de classes, motivo pelo qual foi escolhida para essa pesquisa.

Desenvolvido por Forrester (1961), (iv) o modelo de Dinâmica de Sistemas foi e é muito utilizado em ambientes corporativos, pois permite a compreensão do sistema empresarial com um comportamento que pode ser comparado ao sistema real observado (Zambon *et al.*, 2006). Esse tipo de modelo preditivo tem sido útil na área ambiental (Vaz, Inomata e Maldonado, 2016) e na gestão energética (Sobczak; Borges; Vaz, 2019; Sampaio *et al.*, 2020).

Os modelos Baseados em Regras (v) encapsulam relações entre as variáveis dos modelos e fornecem mecanismos para ligar suas representações com seus respectivos procedimentos computacionais (Pinheiro *et al.*, 2010). Luna, Soares e Ballini (2007) afirmam que várias metodologias são utilizadas na elaboração de modelos Baseados em Regras, como os algoritmos de agrupamento, os métodos baseados na alocação de modelos locais ou especialistas e os baseados em conjuntos aproximados. Exemplos de aplicações dessa classe de modelo podem ser visualizados nos trabalhos de Lunetta e Peixoto (2021) e Neves, Duarte e Alvarado (2019), que se propuseram, respectivamente, a avaliar o processo de ensino-aprendizagem e a qualidade da água com sistemas baseados em regras.

O modelo Random Forest (vi) é popular na tecnologia da geoinformação. É um método usualmente utilizado como método de reconhecimento de padrões na classificação de imagens digitais e na simulação de cenários futuros. Este classificador pode ser usado para selecionar e classificar as variáveis com maior habilidade para discriminar os alvos entre as classes (Belgiu; Drăgu, 2016).

O modelo escolhido nesse trabalho, (vii) CA-Markov, encaixa-se na classe dos Híbridos de Autômatos Celulares. Para Aburas, Ahamad e Omar (2019), os Autômatos Celulares são uma categoria de modelos dinâmicos comumente utilizados nos estudos de uso e cobertura da terra. Têm como principais vantagens a sua simplicidade e a possibilidade de integração com outros modelos e apresenta como desvantagem a incapacidade de incluir fatores socioeconômicos na análise.

O conceito de Autômato Celular foi elaborado pela primeira vez por John von Neumann, em 1940, primeiramente denominado de *Universal Constructor*. Com base nas pesquisas desenvolvidas por Neumann, John Conway desenvolveu em 1970 um Autômato Celular bidimensional chamado de *Jogo da Vida*, com maior potencial para simular comportamentos dinâmicos (Ody; Viali, [2016?]). Nesse algoritmo, foi implementada a capacidade de evolução das células a partir da noção de vizinhança. A linha do tempo com a evolução temporal desse algoritmo continua em 1983, com a criação dos Autômatos Celulares Elementares (Ciolpan, 2022; Reis; Venturelli, 2020).

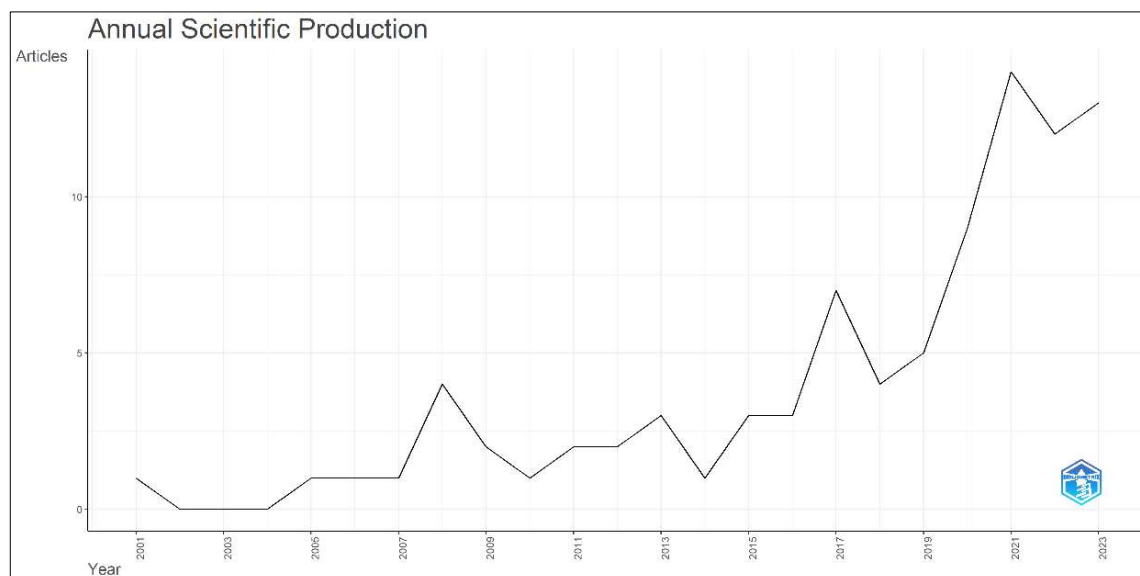
Os híbridos de Autômatos Celulares surgiram a partir da possibilidade de integração dos Autômatos Celulares com outros modelos. O modelo híbrido escolhido para análise nessa pesquisa é uma associação dos Autômatos Celulares com a Cadeia de Markov (CA-Markov) e tem sido bastante utilizado na avaliação e na predição de cenários de uso e de cobertura da terra (Kulkarni; Vijaya, 2021; Avtar *et al.*, 2022; Hoque *et al.*, 2022; Tajbakhsh; Memarian; Kheyrikhah, 2018).

O modelo CA-Markov também pode ser chamado de um modelo de série temporal. Segundo Navin e Agilandeeswari (2020), a Cadeia de Markov é um modelo de transição estocástica que simula o cenário no tempo “ $t+1$ ” com base em uma matriz de transição de mudanças, enquanto os Autômatos Celulares se baseiam no cálculo espaçotemporal de um estado de tempo “ t ” para outro “ $t+1$ ”. A principal vantagem da integração entre esses modelos está na possibilidade de inclusão de fatores externos na análise proporcionada pela Cadeia de Markov.

2.3 Modelos preditivos no sensoriamento remoto

Com a atenção cada vez maior destinada ao planejamento do uso e cobertura da terra de forma a entender as causas de diversas problemáticas ambientais atuais, foram desenvolvidos diversos modelos que permitem a simulação das mudanças na paisagem. Os principais documentos publicados nas bases de dados *Web of Science* e *Scopus* envolvendo a simulação de cenários futuros de uso e cobertura da terra, segundo o pacote *Bibliometrix* implementado no *software* estatístico R, datam do ano de 2021, como se pode visualizar no Gráfico 1.

Gráfico 1 - Produção científica anual sobre modelos preditivos em sensoriamento remoto



Fonte: Bibliometrix (2023).

É possível perceber que, durante a última década, houve uma ascensão no interesse de pesquisadores por essa área de conhecimento, o que pode ser creditado ao avanço da inteligência artificial e da capacidade de processamento dos computadores. Os países onde há mais publicações nessa área são, respectivamente, os Estados Unidos da América (EUA), a Índia e a China. Aburas, Ahamad e Omar (2019) comentam sobre a variedade de modelos preditivos utilizados atualmente, como os dinâmicos, os baseados na aprendizagem de máquinas e os estatísticos, e destacam a possibilidade de integração entre esses modelos e os *softwares* de Sistemas de Informações Geográficas. Na abordagem dinâmica “o espaço é representado através de um *array* de células em que cada célula pode assumir diferentes estados ao longo do tempo” (Druck *et al.*, 2004, p.1).

Nessa esfera, os Autômatos Celulares são um exemplo de modelos dinâmicos e seu uso é bem difundido no campo científico, especialmente em combinação com outras abordagens metodológicas, cujas pesquisas podem ser aqui citadas: Agustina *et al.* (2022) fizeram uso dos autômatos celulares para predição do uso e cobertura da terra em Cirebon, Indonésia; He, Huang e Li (2017) avaliaram o impacto das mudanças de uso e cobertura da terra na qualidade do *habitat* com a contribuição dos autômatos celulares em cenários futuros e utilizaram o modelo InVest, que permitiu avaliar a qualidade do habitat. Ambos os autores obtiveram êxito em seus resultados.

Algoritmos baseados em aprendizagem de máquinas são comumente utilizados em análises de sensoriamento remoto, tendo sido implementados, inclusive, em *softwares* de Sistemas de Informações Geográficas para o reconhecimento de padrões na classificação de imagens de satélite. Segundo Lary *et al.* (2016), a aprendizagem de máquinas é categorizada como uma subdivisão da inteligência artificial e engloba algoritmos como as Redes Neurais Artificiais, Support Vector Machine, Self-organizing map, Árvores de Decisão e Random Forests. Nesse vasto campo, diversas pesquisas têm se mostrado promissoras e dão base para a pesquisa aqui desenvolvida.

Lukas, Melesse e Kenea (2023) predisseram mudanças futuras de uso e cobertura da terra no alto curso da bacia hidrográfica do rio Omo-Gibe, na Etiópia, utilizando um protótipo composto por Autômatos Celulares e Redes Neurais Artificiais. Os modelos geraram resultados com uma acurácia global de 86,53% e um índice Kappa de 0,82 na comparação entre o modelo predito de 2022 e o mapa produzido com dados orbitais de 2022.

Sundar e Deka (2022) escolheram três abordagens baseadas na aprendizagem de máquinas que são o Random Forest, Classification and Regression Trees (CART) e Support Vector Machine (SVM) para a classificação e predição das mudanças do uso e cobertura da terra no Lago Vembanad, em Kerala, na Índia. A comparação entre as técnicas demonstrou que o *Random Forest* foi o método que apresentou a melhor acurácia, com 89,5%, sendo escolhido para simular os mapas durante o período entre 2035 e 2050.

No trabalho produzido por Kulkarni e Vijaya (2021), os autores utilizaram o índice Normalized Difference Built-up como variável externa para alcançar resultados mais precisos na predição do uso e cobertura da terra. Para atingir esse fim, foi utilizado o método de classificação de imagens Random Forest para obtenção dos mapas de 2013, 2016 e 2019, escolhidos como dados de entrada no modelo de predição, e um modelo combinado envolvendo os métodos do Multilayer Perceptron (MLP) e Autômatos Celulares (CA). A validação dos resultados ocorreu ao confrontar o mapa observado de 2019 com o mapa produzido na modelagem.

Com relação às ferramentas metodológicas estatísticas, elas podem ser utilizadas isoladamente ou em conjunto com outros modelos, como é o caso da Cadeia de Markov combinada com os Autômatos Celulares. Li e Zhang (2009) afirmam que a Cadeia de Markov é “um processo que consiste em um número finito de estados com

as propriedades Markovianas e algumas probabilidades de transição p_{ij} , em que p_{ij} é a probabilidade de mudança de um estado i para j ” (p. 455, tradução própria). Segundo Cunha *et al.* (2021) e Permatasari *et al.* (2021), essa ferramenta se baseia na execução de uma matriz de probabilidade de transição entre as classes presentes nos dados de entrada como condição para prever e simular os eventos futuros. Entende-se ainda que o modelo de Markov é um método estocástico usado principalmente na modelagem do uso e cobertura da terra, relacionando as mudanças da paisagem ao seu estado futuro (Lu *et al.*, 2019).

Devido a sua rentabilidade para esses fins, o funcionamento do modelo de Markov é o alvo de estudo dessa pesquisa. Essa técnica vem sendo validada em diversas pesquisas, como: Lu *et al.* (2019); Khwarahm *et al.* (2021); Permatasari *et al.* (2021); Abijith e Saravanan (2022); Hamad, Balzter e Kolo (2018); Floreano e Moraes (2021); Karimi *et al.* (2018); Khan, Saeed e Bazai (2020); Aniah *et al.* (2023); Maurya, Rafi e Shamoo (2023) e Cunha *et al.* (2021).

O próximo tópico apresentará o estado da arte a respeito do uso do modelo híbrido de Autômatos Celulares e a Cadeia de Markov, a fim de compreender as suas vantagens e desvantagens no ramo do sensoriamento remoto de uso e cobertura da terra.

2.3.1 Cadeia de Markov e CA-Markov na predição do uso e cobertura da terra

Em termos gerais, os modelos de Markov são capazes de simular as mudanças de uso e cobertura da terra através de uma matriz de probabilidade de transição, porém, não têm a capacidade de prever alterações em tendência espacial (Cunha *et al.*, 2021). É por essa desvantagem que surgiu a necessidade de incorporar os Autômatos Celulares ao modelo de Markov e assim obter uma metodologia mais precisa para a dinâmica de transição do uso e cobertura da terra.

O modelo CA-Markov já foi validado em diversas regiões e áreas do conhecimento, sendo principalmente utilizado no planejamento urbano e no monitoramento dos recursos naturais. Como exemplo de uso dessa ferramenta metodológica no planejamento urbano, é possível citar Karimi *et al.* (2018), que simularam as mudanças na paisagem na cidade de Ravansar, localizado no distrito de Ravansar, no Irã. Foi avaliada a dinâmica espacial de mudanças na área de estudo até o ano de 2030 com base em dados orbitais obtidos no período entre 1992 e 2015.

Os autores observaram um incremento de áreas urbanas e agrícolas, seguindo uma tendência também comprovada pela simulação efetuada com o modelo de CA-Markov.

Essa tendência de expansão de áreas urbanas e de áreas agrícolas também foi observada por Mahamud *et al.* (2019), Mathanraj, Rusli e Ling, (2021) e por Xiong *et al.* (2022). Mahamud *et al.* (2019) projetaram um cenário futuro para o ano de 2025, com o modelo CA-Markov, em Kelantan, na Malásia, com uma acurácia de 78,57%. Mathanraj, Rusli e Ling (2021) encontraram resultados semelhantes em Batticaloa, no Sri Lanka, ao analisar o período compreendido entre 1990 e 2020 e simular um cenário futuro para o ano de 2030. No trabalho elaborado por Xiong *et al.* (2022), executado no Condado de Qishan, na China, os autores observaram, além do aumento significativo na área urbana nos anos de 2000 a 2020, uma necessidade de proteção dos ecossistemas mais vulneráveis com foco na proteção dos recursos hídricos.

Outros trabalhos reforçam a importância e a necessidade dessas pesquisas com a utilização dessa mesma ferramenta. Hamad, Balzter e Kolo (2018), utilizaram a metodologia de CA-Markov na predição do uso e cobertura da terra no National Park na região do Curdistão, no Iraque. Foram testados diferentes cenários, sendo o primeiro correspondente ao período compreendido entre 1993 e 2003 e o segundo contido entre 2003 e 2017. Foi obtida uma acurácia superior a 80% no modelo preditivo considerando todos os cenários, porém os autores apontaram como ponto negativo da metodologia o fato de não poderem adicionar dados ambientais, sociais e demográficos.

Lu *et al.* (2019) otimizaram o modelo CA-Markov ao adicionar como dados de entrada para o modelo dados resultantes da técnica de fusão de imagens para reduzir os efeitos da variação fenológica em Henfei, na China. Com a análise temporal e a simulação do cenário futuro foi possível observar a partir de que ano haverá um decaimento na taxa de expansão urbana do município.

No trabalho produzido por Singh, Venkatramanan e Deshmukh (2022), os autores determinaram a taxa de transformações da paisagem, suas causas e consequências bem como a predição do crescimento urbano em Delhi, Índia. O modelo CA-Markov simulado previu um aumento de 24,30% na área urbana de 2030 com um coeficiente Kappa equivalente a 0,96.

Bakr, Morsy e Yehia (2022) aplicaram o modelo CA-Markov para detectar a mudança histórica na elevação da superfície e identificar a dinâmica de mudanças

das classes de uso e ocupação da terra no Lago Idku, na região mediterrânea. A análise temporal identificou uma redução na área superficial ocupada pelos corpos hídricos e uma ampliação nas áreas agrícolas, tendo sido previsto que até o ano de 2030 a agricultura terá ocupado um espaço equivalente a 74% e 70% da área de estudo.

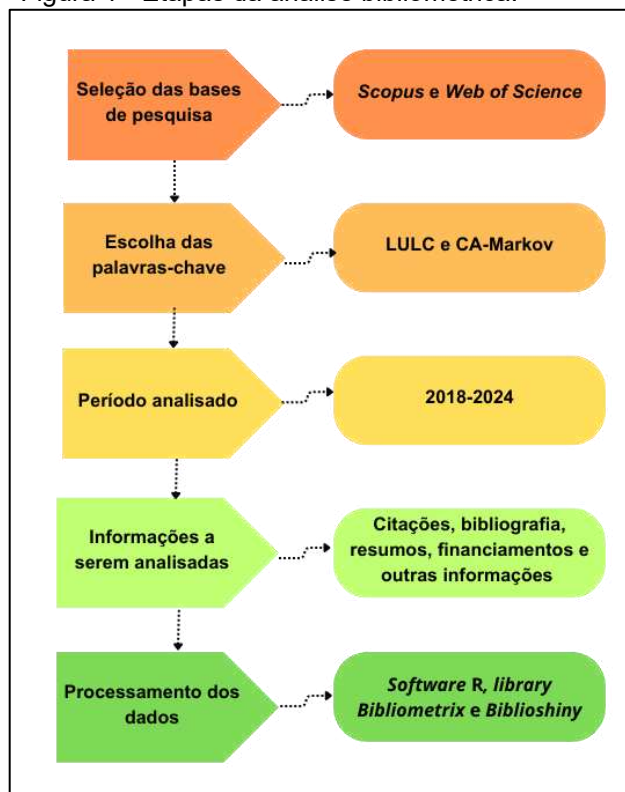
O modelo preditivo CA-Markov também vem sendo aplicado no manejo e conservação dos recursos naturais. Aniah *et al.* (2023) utilizaram o modelo da CA-Markov na zona da Savana ecológica de Ghana. Os resultados revelaram um aumento nas terras agrícolas de 10,03% para 27,17% entre os anos de 1990 e 2019 no Distrito de Bongo, assim como um aumento na área ocupada por Savana no mesmo período no Distrito de Kassena-Nankana West. As predições indicaram que a tendência observada na análise temporal deve ser mantida até o ano de 2050.

No Brasil, uma das principais pesquisas desenvolvida com o modelo híbrido CA-Markov na conservação e no manejo dos recursos naturais foi executada por Cunha *et al.*, (2021) no ecótono Cerrado-Mata Atlântica. Foi analisado o avanço da agricultura em áreas de vegetação nativa tendo por base as mudanças no uso e cobertura da terra com uso das imagens registradas pela série de satélites Landsat nos anos de 1986, 1999, 2007 e 2016. A modelagem indicou o avanço da área agrícola e o decaimento das áreas úmidas como o banhado, a savana, vegetação ripária, floresta semidecidual e áreas alagadas, o que foi considerado como uma perda na biodiversidade na fauna e na flora no Parque Nacional da Serra da Bodoquena na bacia hidrográfica do rio da Prata.

2.3.2 Análise Bibliométrica

O passo a passo da metodologia utilizada para a execução da análise bibliométrica está apresentado na Figura 1 com esquema de fluxograma. A Library Bibliometrix, implementada no *software* R, foi escolhida para o processamento dos dados. Os dados foram obtidos nas bases de pesquisa da Web of Science e Scopus no período compreendido entre 2018 e novembro de 2024, correspondendo aos anos mais recentes do que foi publicado na literatura científica.

Figura 1 - Etapas da análise bibliométrica.



Fonte: elaborado pelo autor.

Foram identificadas, no período estudado, aproximadamente 263 publicações científicas produzidas por 936 autores com uma média de citações por documento equivalente a 24,94, no período entre 2018 e 2024. O Quadro 1 sintetiza as principais informações sobre o tema obtidos com o Bibliometrix.

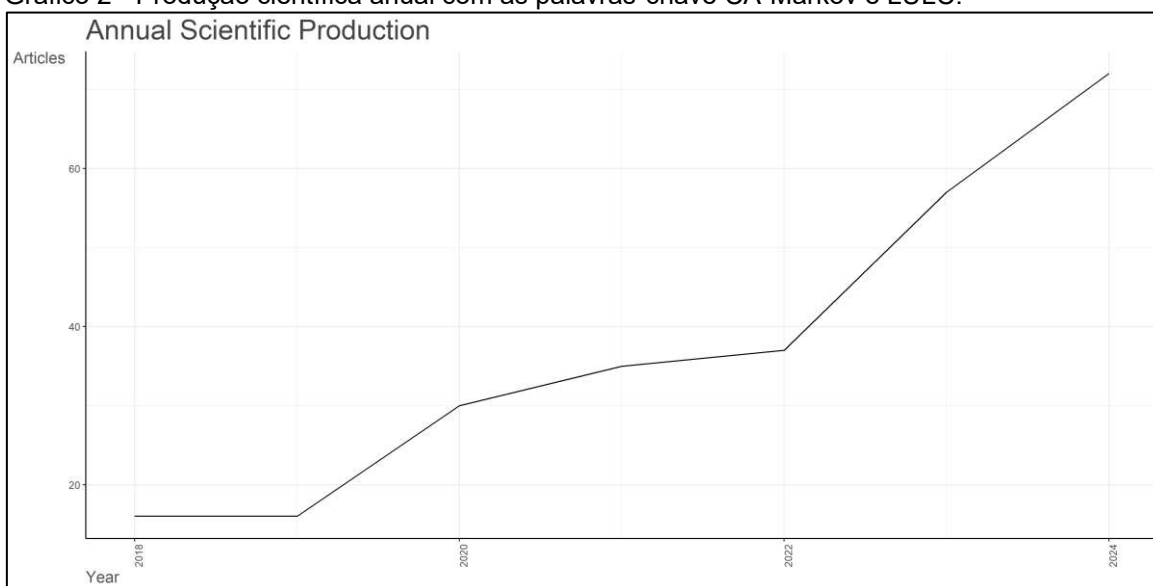
Quadro 1 - Principais informações bibliométricas.

Documentos produzidos	263
Autores	936
Média de citações por documento	24,94
Coautores por documento	4,34
Documentos com um único autor	9
Referências	15662

Fonte: Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

O gráfico com a produção científica anual mostra uma tendência de crescimento no uso da CA-Markov associada ao LULC, sendo o ano de 2024 o mais produtivo, com mais de 60 publicações, seguido por 2023 (Gráfico 2).

Gráfico 2 - Produção científica anual com as palavras-chave CA-Markov e LULC.

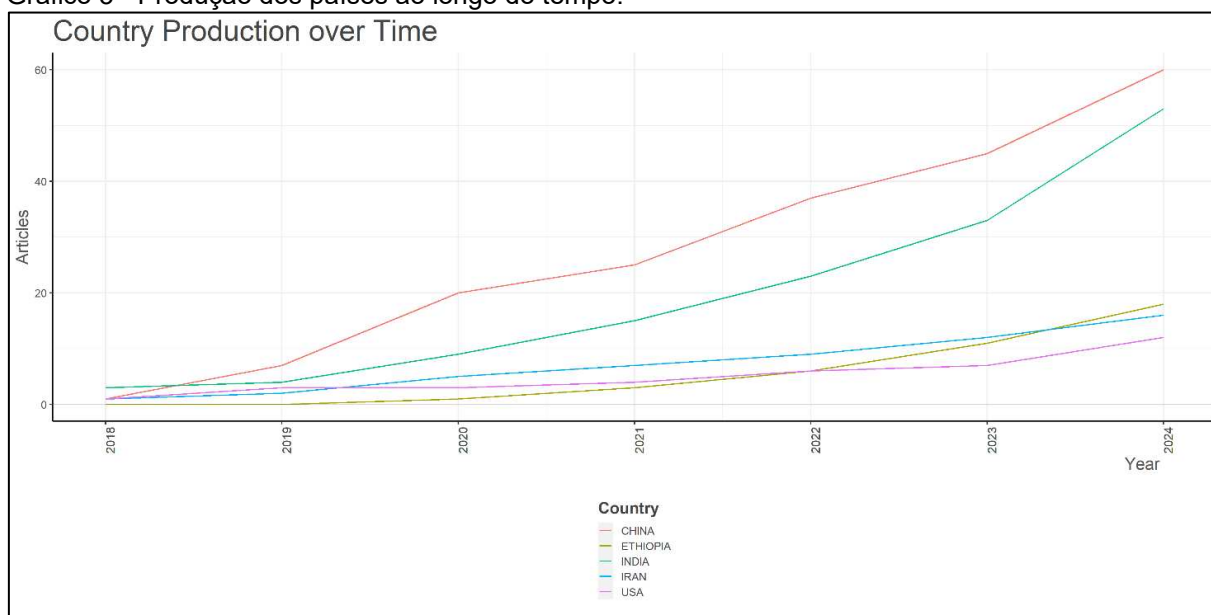


Fonte: Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

Com relação à produção científica dos países no uso e cobertura da terra com o modelo integrado CA-Markov, a China se destaca em sua produtividade com 195 documentos publicados, seguida por Índia, Irã, Etiópia e EUA com 140, 52, 39 e 36 documentos, respectivamente. Especificamente com relação aos mais relevantes institutos de pesquisa, a Addis Ababa University, Beijing University, Wuhan University e Hohai University se destacam.

O Gráfico 3, com a produção dos países ao longo do tempo, indica que o interesse por essa área de conhecimento cresceu, principalmente na China e na Índia, a partir de 2020, o que talvez possa ser atribuído ao *boom* da inteligência artificial ocorrido nos últimos anos.

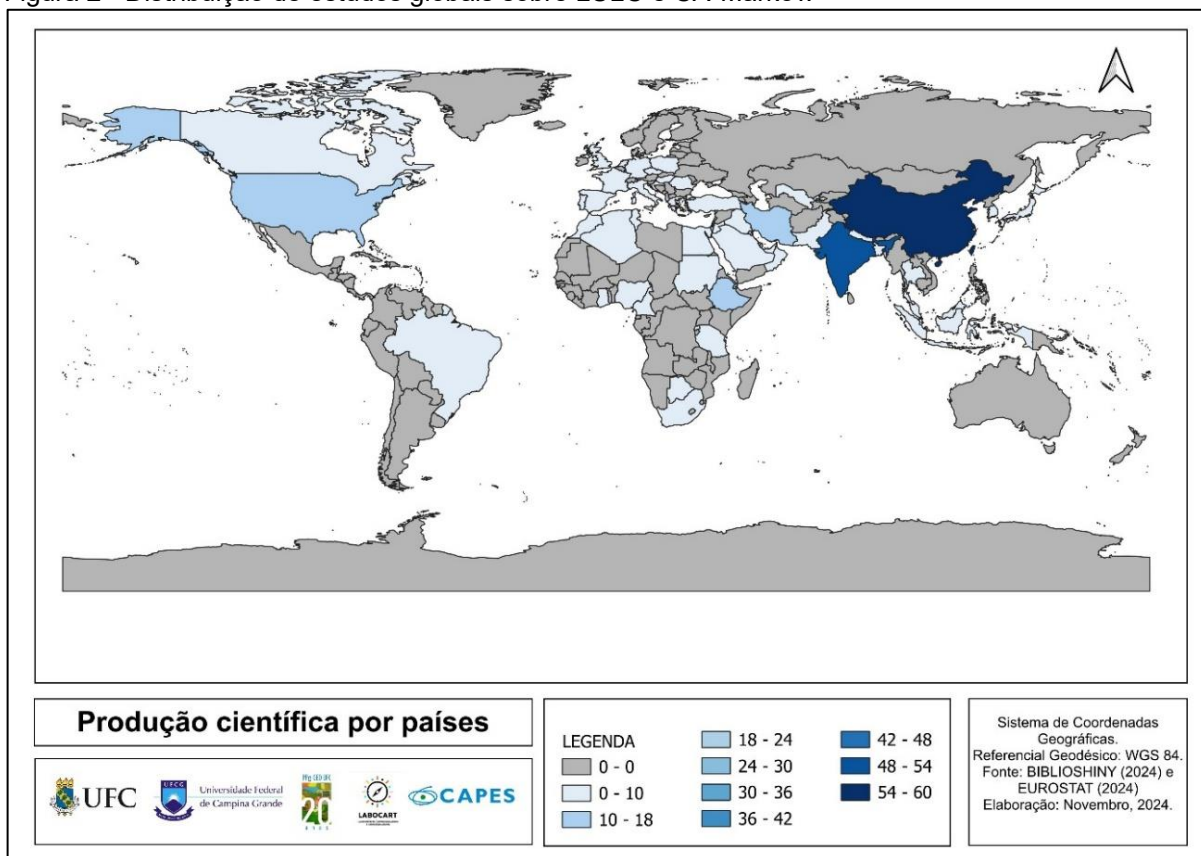
Gráfico 3 - Produção dos países ao longo do tempo.



Fonte: Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

O mapa coroplético apresentado na Figura 2, inserido abaixo, contribuiu com a análise bibliométrica ao mostrar a distribuição espacial da quantidade de publicações científicas por países, considerando o período em análise. O mapa refletiu o que foi visualizado no Gráfico 03, indicando que os países que mais se destacaram no uso da CA-Markov aplicada ao LULC foram a China e Índia, seguido da Etiópia, Irã e EUA.

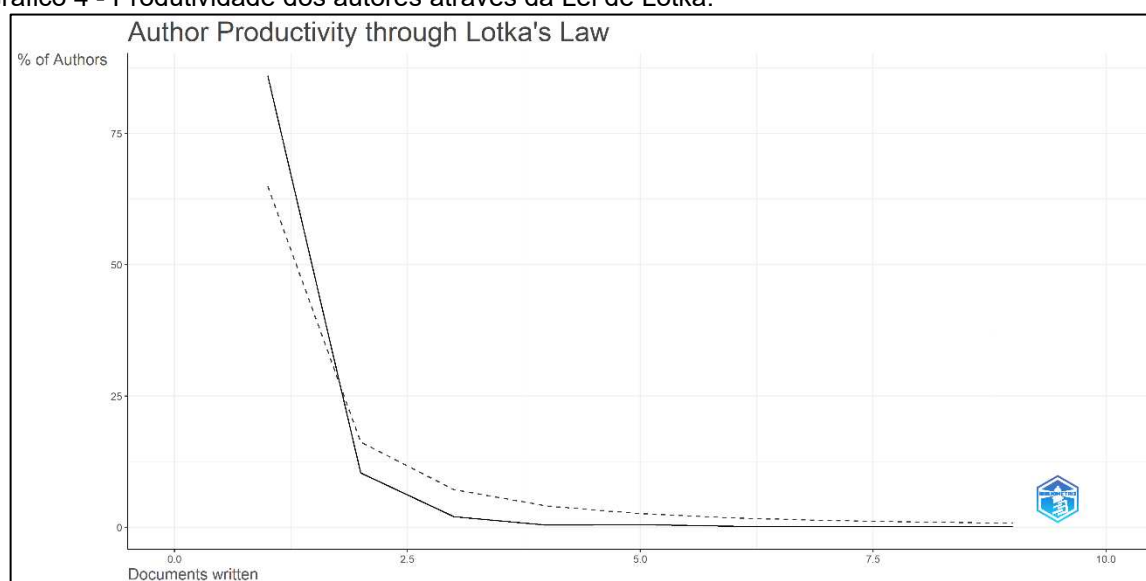
Figura 2 - Distribuição de estudos globais sobre LULC e CA-Markov.



Fonte: Adaptado do Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

De acordo com a Lei de Lotka (Lotka, 1926), que investiga a produtividade acadêmica dos pesquisadores, aproximadamente 77,4% dos autores publicaram em média 1 artigo enquanto apenas 0,005% dos pesquisadores publicaram mais de cinco artigos nessa temática (Gráfico 4).

Gráfico 4 - Produtividade dos autores através da Lei de Lotka.



Fonte: Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

No Quadro 2 estão listados os dez autores mais relevantes nessa área do conhecimento. O quantitativo de publicações está distribuído homogeneamente entre os diversos autores, sendo S. Singh, P. Kumar e A. Tariq os principais pesquisadores com 9, 8 e 7 documentos produzidos, respectivamente.

Quadro 2 - Principais autores na área do conhecimento da CA-Markov e LULC.

Autores	Artigos
S. SINGH	9
P. KUMAR	8
A. TARIQ	7
S. KANGA	6
Y. LI	6
J. DEBNATH	5
M. FAROOQ	5
D. LAHON	5
F. MUMTAZ	5

Fonte: Bibliometrix (2024). Disponível em: <https://www.bibliometrix.org/home/>.

A nuvem de palavras observada na Figura 3 mostra que a expressão CA-Markov, utilizada como palavra-chave na análise bibliométrica, está frequentemente relacionada a outros vocábulos como o crescimento urbano, as mudanças de uso e cobertura da terra, o monitoramento ambiental, o desenvolvimento sustentável, a conservação dos recursos naturais, a proteção ambiental, a agricultura e a tomada de

A análise bibliométrica com as palavras-chave da CA-Markov e LULC permitiu o conhecimento dos aspectos quantitativos a respeito da produção científica global e possibilitou o entendimento no que diz respeito à área de aplicação em que os métodos estão sendo empregados, como as mudanças climáticas e o desenvolvimento sustentável.

2.4 Considerações finais

A inclusão dos modelos preditivos de uso e cobertura da terra como ferramenta de suporte ao planejamento ambiental e ao manejo dos recursos naturais é relativamente recente. Pesquisadores, procedentes principalmente de países como da China e a Índia, propuseram-se a estudar os benefícios da modelagem da dinâmica de mudanças da paisagem para o monitoramento ambiental principalmente nas últimas décadas.

O modelo híbrido CA-Markov, foco de estudo dessa pesquisa, é uma junção dos Autômatos Celulares com o método estatístico da Cadeia de Markov, união que permite a inclusão de variáveis explicativas ao modelo para uma melhor precisão dos resultados. Esse modelo é objeto de estudo de aproximadamente 1654 autores localizados principalmente na China, sendo utilizado com mais afinco na última década. Entre as principais palavras-chave ocorrentes nas publicações científicas em associação a essa metodologia, encontram-se o monitoramento ambiental, o desenvolvimento sustentável e a conservação dos recursos naturais.

O estado da arte acerca do que vem sendo produzido com CA-Markov nos últimos cinco anos demonstra que a principal área de aplicação até o momento tem sido o planejamento urbano. Pesquisas envolvendo o manejo e conservação dos recursos naturais ainda são incipientes. No Brasil, alguns pesquisadores como Cunha *et al.* (2021), Floreano e Moraes (2021), Santos *et al.* (2024), Bacani *et al.* (2024), Fernandes *et al.* (2020) e Feitosa *et al.* (2023) aplicaram o modelo CA-Markov. Um desafio para essa metodologia é adaptá-la para uso no bioma Caatinga, considerando todas as peculiaridades dessa região, como o seu aspecto caducifólio e as estratégias de adaptação às mudanças climáticas adotadas pela população, sendo esta e demais características apresentadas no capítulo a seguir.

3 CARACTERIZAÇÃO AMBIENTAL DA ÁREA DE ESTUDO

3.1 Introdução

O conhecimento dos aspectos fisiográficos e socioeconômicos é fundamental para a compreensão das problemáticas ambientais ocorrentes em uma região. Em uma bacia hidrográfica, palco desse estudo, a interação entre os diversos fatores bióticos e abióticos presentes é importante para o entendimento dos aspectos hidrológicos baseados na qualidade e na disponibilidade hídrica. Nessa pesquisa, foi adotada como área de estudo a sub-bacia hidrográfica do rio Banabuiú em virtude da importância que ela possui para o estado do Ceará e por sua localização. Dados recentes da Funceme (c2024) apontam que o local possui uma capacidade de acumulação de águas superficiais de 2.760.549.943 de m³, com 19 açudes públicos. Essa região hidrológica abrange quinze municípios, que são: Banabuiú, Boa Viagem, Ibicuitinga, Itatira, Jaguaratama, Madalena, Milhã, Mombaça, Monsenhor Tabosa, Morada Nova, Piquet Carneiro, Quixadá, Quixeramobim e Senador Pompeu, sendo os municípios de Morada Nova e Quixeramobim os detentores dos maiores índices de Produto Interno Bruto (PIB) da região.

Apesar de sua importância regional, a área de captação do rio Banabuiú apresenta pontos de degradação ambiental. Lima e Silva (2018) associaram esse processo degradante ao despejo de esgotos domésticos e industriais nos mananciais, à má gestão do uso e cobertura da terra e ao desmatamento, realizado principalmente pelas atividades de agropecuária e de expansão urbana. Segundo Tritsch *et al.* (2023), os anos de seca também trouxeram várias consequências drásticas para a região em muitas atividades, como o abastecimento de água para o consumo humano e a produção agrícola.

Estudos recentes, como Silva e Mendes (2019) e Lima e Silva (2018), encontraram uma predominância de áreas moderadamente susceptíveis à erosão laminar, sendo que os recursos hídricos são os mais vulneráveis aos riscos ambientais. Apesar dessa conjuntura, Silva e Lima (2017) observaram que 92% dos municípios pertencentes apresentam desempenho sustentável, potencialmente sustentável e de sustentabilidade média.

Com a execução desse capítulo, pretende-se caracterizar ambientalmente a sub-bacia hidrográfica do rio Banabuiú como forma de obter embasamento científico

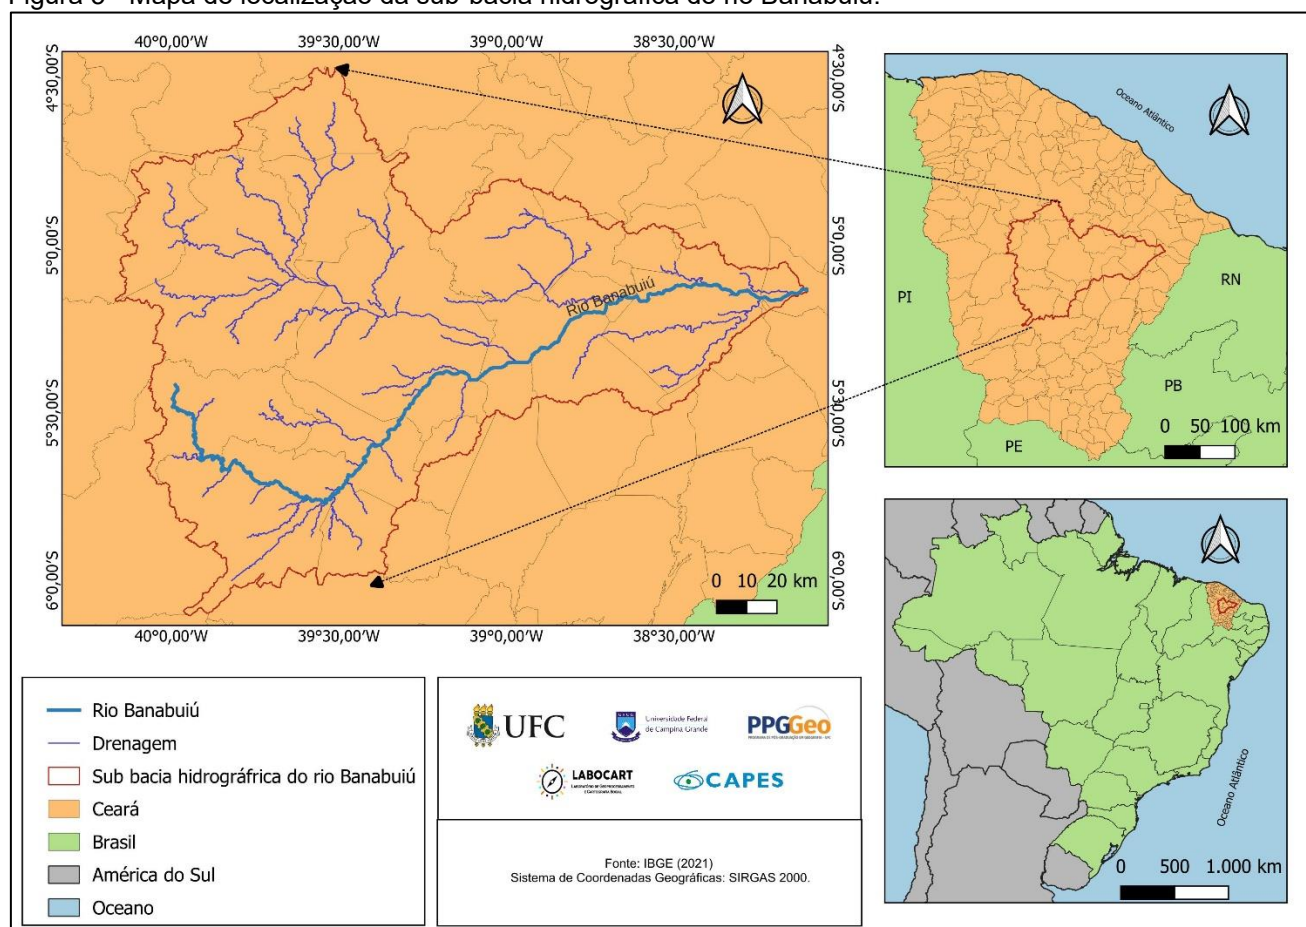
para uma melhor compreensão a respeito das problemáticas existentes. Serão estudados aspectos socioeconômicos e físicos como os recursos hídricos, o clima, a geologia, a pedologia, a geomorfologia e a vegetação que estão descritos em tópicos separadamente a seguir.

3.2 Localização

A localização da sub-bacia hidrográfica do rio Banabuiú (Figura 5) contribuiu para a decisão do local sobre o qual desenvolver essa pesquisa, pois se limita com quase todas as áreas de captação do estado e “compreende os sertões centrais do Ceará mais fortemente submetidos aos rigores da semiaridez” (Ceará, 2009, p.16).

A área de captação se destaca pela sua extensão territorial com uma área superficial semelhante a 19.603,094 km², abrangendo quinze municípios cearenses. Do ponto de vista das características hidrológicas, a área de estudo possui uma densidade de drenagem (Christofolletti, 1980) considerada pobre, equivalente a 0,116 km/km².

Figura 5 - Mapa de localização da sub-bacia hidrográfica do rio Banabuiú.



Fonte: elaborado pelo autor.

3.3 Procedimentos metodológicos

A metodologia adotada para o que está exposto nesse capítulo consistiu na consulta bibliográfica do que já foi produzido na área de estudo e no levantamento de dados cartográficos disponibilizados em plataformas governamentais, como o Instituto Brasileiro de Geografia e Estatística (IBGE), o Serviço Geológico do Brasil (SGB), a Plataforma Estadual de Dados Espaciais Ambientais do Ceará (PEDEA) e a Companhia de Gestão dos Recursos Hídricos do Ceará (Cogerh), além dos dados do Copernicus, pertencente ao Programa de Observação da Terra da União Europeia.

As informações de hipsometria utilizadas nessa pesquisa foram obtidas do Copernicus DEM, pois, segundo Bielski *et al.* (2024), o Modelo Digital de Elevação desse instrumento se destaca com uma superioridade significativa em comparação com os outros cinco MDEs globais disponíveis atualmente. Foram obtidos produtos da categoria DGED (*Digital Gridded Elevation Data*) com valores decimais e resolução

espacial de 30 metros.

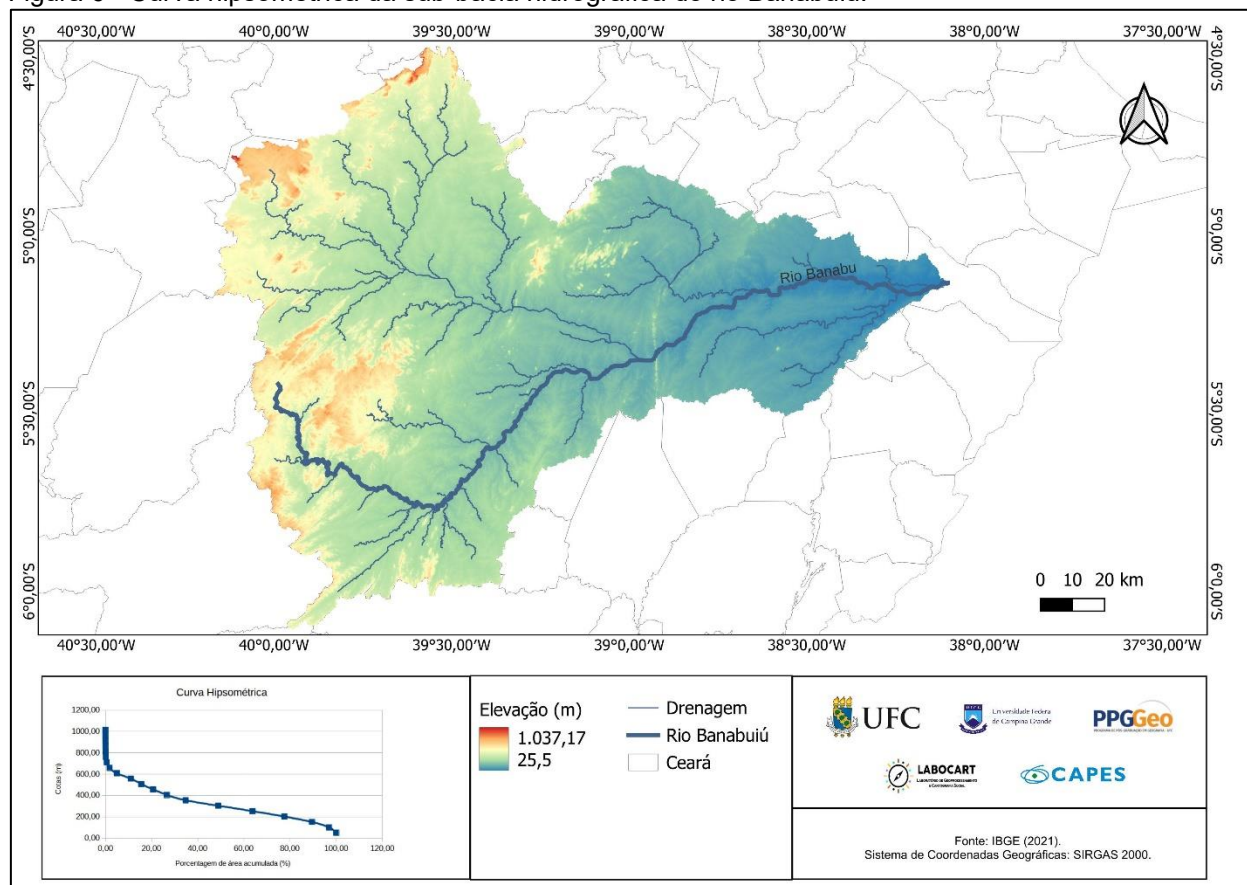
A delimitação da sub-bacia hidrográfica do rio Banabuiú foi obtida no PEDEA-CE e os dados históricos referentes a pluviometria, balanço hídrico, índice de aridez e evapotranspiração de referência média anual correspondentes ao período de 1974 a 2016 foram adquiridos na Fundação Cearense de Meteorologia e Recursos Hídricos (Funceme, [2023?]). Os dados geológicos, pedológicos, geomorfológicos e de vegetação foram obtidos no *site* do IBGE na escala de 1:250.000. Os dois aspectos são referentes ao ano de 2021.

3.4 Aspectos fisiográficos

3.4.1 Recursos hídricos e Hipsometria

O rio principal dessa área de captação é o rio Banabuiú que possui uma extensão de aproximadamente 2.281,64 km. O balanço hídrico, calculado pelo Pacto das Águas em 2009, indica que a demanda total de água na região hidrográfica do rio Banabuiú foi equivalente a 9,3 (m³/s), sendo 0,32 (m³/s) disponibilizado para a área urbana, 0,29 (m³/s) para demanda industrial e 8,75 (m³/s) para demanda de irrigação. A altitude observada no local varia entre 75,75 m e 1.040 m com uma elevação média de 300,69 m e declividade média equivalente a 26,55 %. A Figura 6 está apresentada logo abaixo para visualizar a distribuição da altitude na área de estudo e analisar as possíveis influências do relevo no balanço hídrico.

Figura 6 - Curva hipsométrica da sub-bacia hidrográfica do rio Banabuiú.



Fonte: elaborado pelo autor.

A Tabela 1 complementa o entendimento do relevo ao apresentar a proporção de áreas contidas em cada classe de declividade observada no terreno, baseado no sistema de classificação da Embrapa (1979).

Tabela 1 - Classes de declividade observadas na área de estudo.

Declividade (%)	Relevo	Área (km ²)	%
0 - 3	Plano	3.993,10	20,43
3 - 8	Suave-ondulado	7.828,63	40,06
8 - 20	Ondulado	5.561,48	28,46
20 - 45	Forte-ondulado	1.755,89	8,99
45 - 75	Montanhoso	361,42	1,85
>75	Forte-montanhoso	39,59	0,20

Fonte: Adaptado de Embrapa (1979).

O mapa hipsométrico e a Tabela 1 indicam que a sub-bacia hidrográfica do rio Banabuiú apresenta um relevo predominantemente suave-ondulado com seus

picos mais altos nos municípios Monsenhor Tabosa, Boa Viagem, Pedra Branca e Itatira. A faixa de valores de declividade entre 3 e 8% está presente em 40,06% da área de estudo, enquanto apenas 2,05 da área de estudo se enquadram como relevo montanhoso e forte-montanhoso.

3.4.2 Clima

Segundo Ceará (2011), a sub-bacia hidrográfica do rio Banabuiú se enquadra na Classificação Climática de Koppen como Bshw, definido também como Tropical Quente Semiárido, com temperatura média anual de 26,8° C, regime de chuva irregular e pluviosidade anual de 712,4 mm. Brandão e Freitas (2014) relatam que a estiagem prolongada existente na região se dá em virtude de que todos os sistemas produtores de chuva que a atingem atuam por poucos meses.

Os principais fenômenos climáticos vigentes na área de captação são o El Niño e o La Niña, que são responsáveis por provocar, respectivamente, escassez hídrica e chuvas torrenciais.

Dados coletados da Funceme na área de estudo, entre os anos de 1974 e 2016, referentes à precipitação média anual (Prec), à evapotranspiração de referência média anual (EP0) e ao índice de aridez estão apresentados no Quadro 3. Esses valores foram obtidos em 196 estações pluviométricas gerenciadas pelo órgão.

Quadro 3 - Dados climatológicos na sub-bacia hidrográfica do rio Banabuiú (1974 a 2016)

(continua)

Município	Prec	EP(0)	Índice de Aridez	Classificação
Banabuiú	654,9	2004,09	32,68	Semiárido
Boa viagem	621,8	2023,64	30,73	Semiárido
Ibicuitinga	665,9	1986,09	33,53	Semiárido
Itatira	578,1	1765,71	32,74	Semiárido
Jaguaretama	796,2	1996,87	39,87	Semiárido
Madalena	552,4	1855,63	29,77	Semiárido
Milhã	682	1964,81	34,71	Semiárido
Mombaça	720	1867,34	38,56	Semiárido
Monsenhor Tabosa	624	2018,62	30,91	Semiárido
Morada Nova	660,3	1942,14	34,00	Semiárido
Pedra Branca	732,6	1944,67	37,67	Semiárido
Piquet Carneiro	684,1	1945,20	35,17	Semiárido
Jaguaretama	796,2	1996,87	39,87	Semiárido

Quadro 3 - Dados climatológicos na sub-bacia hidrográfica do rio Banabuiú (1974 a 2016)

(conclusão)

Quixadá	686,9	2005,48	34,25	Semiárido
Quixeramobim	672,8	2038,69	33,00	Semiárido
Senador Pompeu	726	1977,33	36,72	Semiárido

Fonte: Funceme (2016).

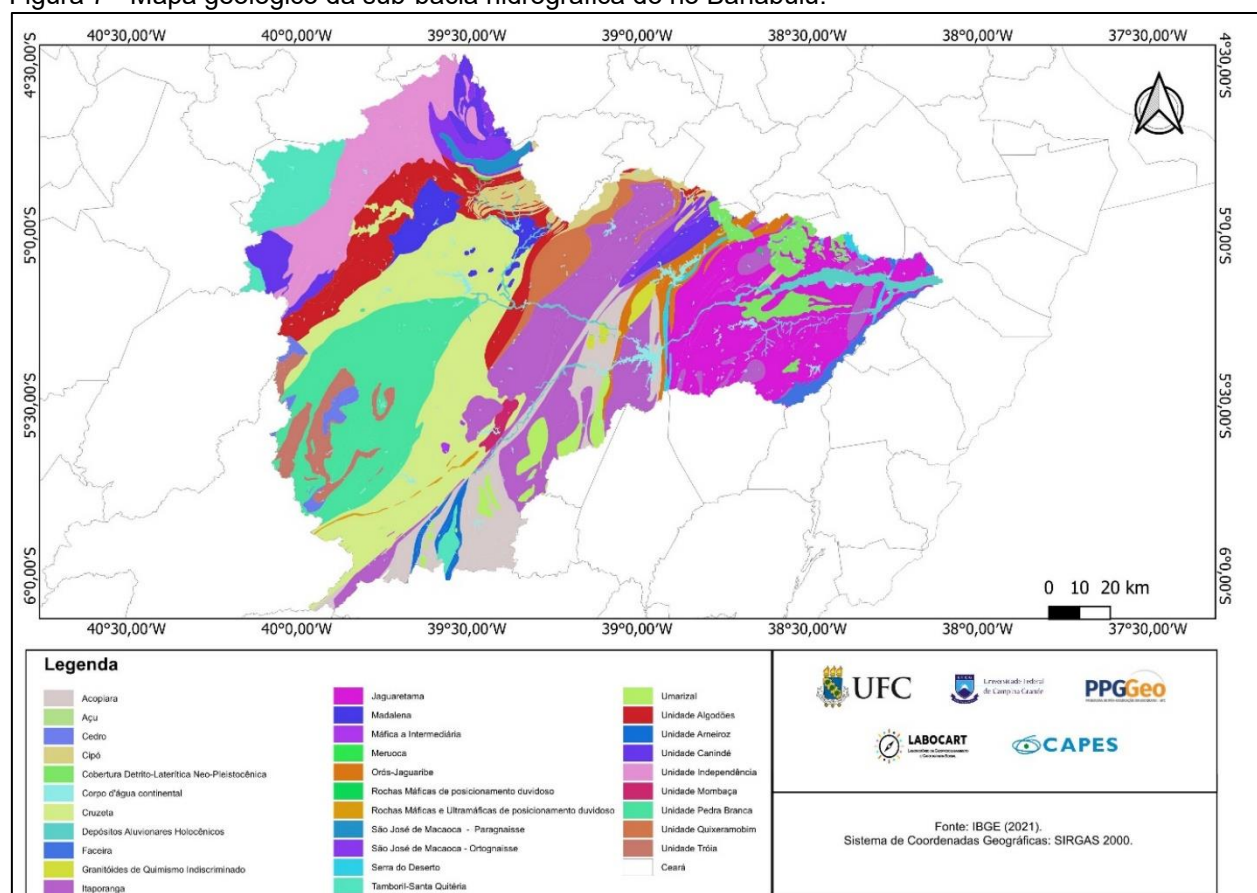
Os valores contidos no Quadro 03 provam a condição semiárida em que a sub-bacia hidrográfica se encontra, com precipitações médias anuais abaixo de 796 mm e evapotranspiração de referência média anual abaixo de 2038,69 mm.

3.4.3 Geologia

Quanto aos aspectos geológicos, há um predomínio, segundo Ceará (2011), de rochas do embasamento cristalino, representadas por gnaisses e migmatitos diversos, associados a rochas plutônicas e metaplutônicas de composição predominantemente granítica, do período Pré-Cambriano. O estudo desenvolvido por Lima e Silva (2018) observou que, quanto à vulnerabilidade natural da estrutura geológica, 72,32% da sub-bacia hidrográfica do rio Banabuiú se encontra próxima à estabilidade, uma vez que setores formados por rochas magmáticas apresentam maiores resistências a processos de intemperismo.

Os dados produzidos pelo IBGE na escala de 1:250 mil e na versão de 2021, que corroboram o que foi observado por Ceará (2011), podem ser visualizados na Figura 7.

Figura 7 - Mapa geológico da sub-bacia hidrográfica do rio Banabuiú.

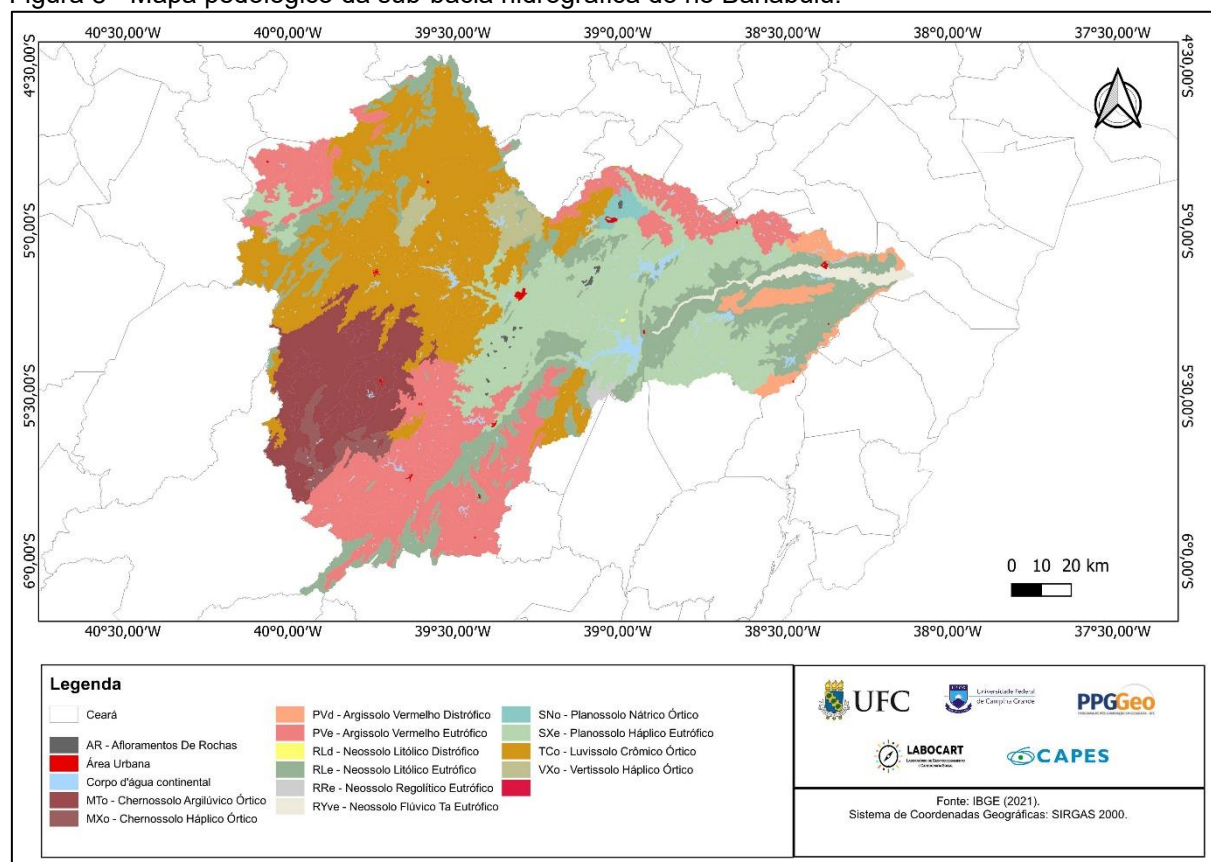


Fonte: elaborado pelo autor.

3.4.4 Pedologia

O levantamento pedológico, segundo Costa, Oliveira e Santos (2019), indica a presença predominante de Planossolos Solódicos, Neossolos Flúvicos e Litólicos, Luvisolos, Argissolos e Chernossolos. O mapa pedológico, executado com os dados do IBGE (c2023), que reafirma o levantamento anterior está apresentado na Figura 8.

Figura 8 - Mapa pedológico da sub-bacia hidrográfica do rio Banabuiú.



Fonte: elaborado pelo autor.

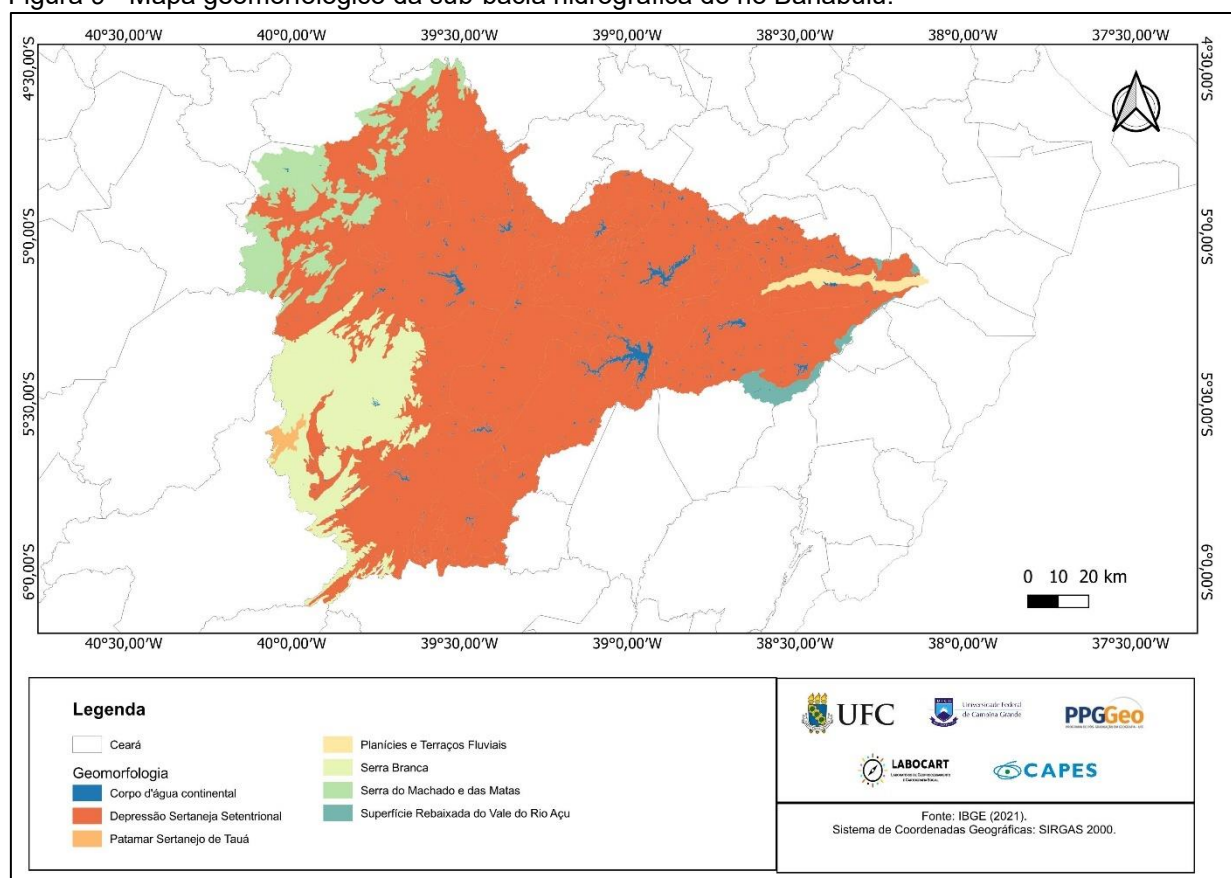
Segundo o Manual Técnico do IBGE (2015), os Argissolos são um dos solos mais predominantes no Brasil e possuem profundidade variável, sendo em geral pouco profundos, enquanto os Chernossolos são solos considerados de boa fertilidade e de pequena e mediana espessura. Já os Neossolos congregam solos rasos, como os Neossolos Litólicos, ou com presença de minerais primários de fácil intemperização, além dos Neossolos Flúvicos formados por uma sucessão de camadas de natureza aluvionar.

3.4.5 Geomorfologia

Como reflexo da hipsometria no local de estudo, a unidade geomorfológica com maior predomínio na área de captação é a Depressão Sertaneja Setentrional seguida pela Unidade Serra Branca, pela Serra do Machado e das Matas no noroeste da região hidrológica. Observa-se também a existência de outras unidades com menor expressividade, mas com menos importância como as Planícies e Terraços fluviais –

como apresentado na Figura 9.

Figura 9 - Mapa geomorfológico da sub-bacia hidrográfica do rio Banabuiú.



Fonte: elaborado pelo autor.

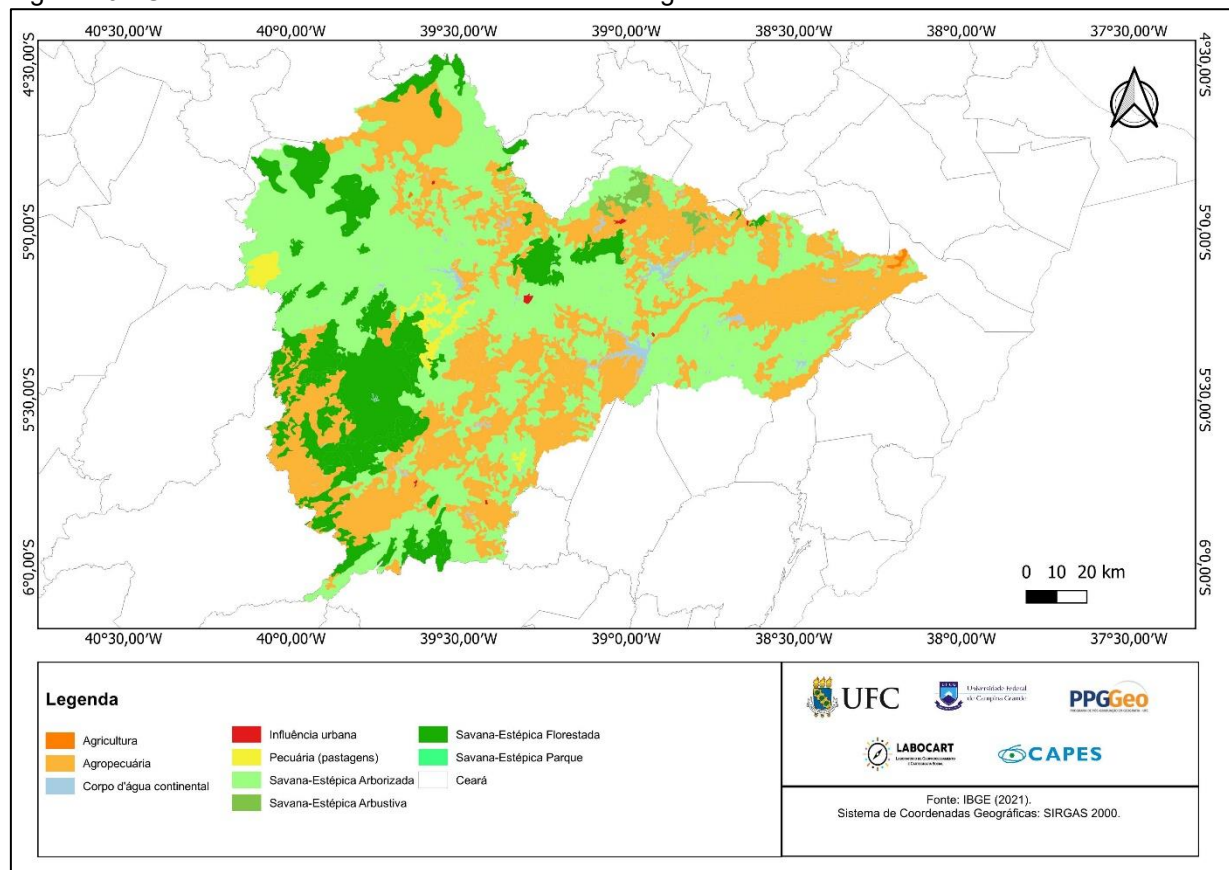
A Depressão Sertaneja se destaca com um amplo predomínio espacial no estado do Ceará, sendo topograficamente mais baixa do que os maciços cristalinos e as chapadas circundantes (Brandão e Freitas, 2014). As Unidades de Serra Branca existentes na área de estudo são caracterizadas, de acordo com o IBGE (2021), como homogênea aguçada e tabular com uma dissecação homogênea ou diferencial. Com relação às planícies fluviais existentes nessa sub-bacia hidrográfica, essas são as áreas mais sujeitas a enchentes periódicas representando um fator limitante para o aproveitamento agrícola (IBGE, c2023).

3.4.6 Uso e cobertura da terra

Os principais tipos de vegetação ocorrentes na área de estudo, que pertence ao bioma Caatinga, são a Savana-Estépica Arborizada, Savana-Estépica Arbustiva, Savana-Estépica Florestada e Savana-Estépica Parque. O levantamento

efetuado pelo IBGE (c2023) também identificou uma presença expressiva da agropecuária em comparação com a agricultura (Figura 10).

Figura 10 - Uso e cobertura da terra da sub-bacia hidrográfica do rio Banabuiú.



Fonte: elaborado pelo autor.

Fuck Junior (2008) afirma que nos terrenos da sub-bacia hidrográfica do rio Banabuiú há uma prevalência da caatinga degradada, sendo os principais tipos a Caatinga Arbustiva Aberta e a Caatinga Arbustiva Densa.

3.4.7 Aspectos socioeconômicos

A descrição dos aspectos socioeconômicos dos municípios compreendidos na área de estudo é de fundamental importância para o entendimento dos padrões de consumo da sociedade. Um resumo com as principais variáveis referentes a população, educação, economia e meio ambiente das quinze cidades contidas na área de estudo estão apresentados na Tabela 2. Os dados foram obtidos na plataforma do IBGE Cidades (IBGE, c2013).

Tabela 2 - População, PIB e IDHM dos municípios presentes na sub-bacia hidrográfica do rio Banabuiú.

Município	População hab (2022)	PIB (R\$) (2021)	IDHM (2010)	Taxa de escolarização de 6 a 14 anos (%) (2010)	Moradores com coleta de esgoto (%) (2022)	Mortalidade infantil (óbitos por mil nascidos vivos) (2020)
Banabuiú	17.195	14,199,25	0,606	98	32,7	8,13
Boa viagem	50.411	9.861,34	0,598	97,6	52,69	10,84
Ibicuitinga	11.611	9.815,44	0,606	97,9	25,45	-
Itatira	20.424	7.903,96	0,562	97,6	30,44	9,4
Jaguetama	17.232	12.498,97	0,612	96,7	20,27	4,44
Madalena	16.896	8.728,00	0,610	98,3	30,08	17,14
Milhã	13.999	14.874,70	0,626	97,5	43,51	21,43
Mombaça	37.735	10.174,82	0,582	96,4	58,24	12,77
Monsenhor Tabosa	17.149	9.308,34	0,610	99,2	61,1	24,77
Morada Nova	61.221	20.731,68	0,610	97,6	27,86	11,58
Pedra Branca	40.187	8.992,69	0,603	97,6	45,6	11,58
Piquet Carneiro	16.616	9.418,47	0,600	96	8,01	25
Quixadá	84.165	12.484,60	0,659	95,8	54,83	21,31
Quixeramobim	82.122	17.008,80	0,642	96,7	67,9	10,62
Senador Pompeu	24.266	13.859,14	0,619	96,4	51,49	11,58

Fonte: elaborado pelo autor.

Os dados apresentados na Tabela 02 demonstram que no ano de 2020 o município com o maior PIB da região foi Morada Nova, em razão da presença do Perímetro Irrigado de Morada Nova, que possui uma área total de 4.474,19 ha (DNOCS, 2021). Contudo, no que diz respeito ao IDHM, o município que apresentou o mais alto valor em 2010 foi Quixadá com 0,659, seguido por Quixeramobim, Milhã e Senador Pompeu.

As cidades que atingiram as maiores taxas de escolarização entre 6 e 14 anos foram Monsenhor Tabosa, Banabuiú, Ibicuitinga, Boa Viagem e Itatira. Com relação às variáveis representativas das categorias de meio ambiente e saúde, porcentagem de esgotamento sanitário adequado e mortalidade infantil, a maior quantidade de óbitos ocorreu em Piquet Carneiro, 25 óbitos por mil nascidos vivos, município com a segunda menor porcentagem de esgotamento sanitário da área de estudo, 8,01%. No que diz respeito ao esgotamento sanitário adequado, Quixadá possui a maior porcentagem de área recoberta por um sistema de esgotamento

sanitário com 52,7%.

3.5 Considerações finais

O conhecimento dos aspectos fisiográficos e socioeconômicos da área de estudo foi importante para entender a relação da população com o modo de ocupação do espaço. Através da análise de todos os aspectos abordados nesse capítulo, tornou-se possível compreender a evolução do uso e ocupação da terra ao longo dos anos, uma vez que as atividades desenvolvidas pela população estão diretamente relacionadas com o seu poder aquisitivo e com as características climáticas, pedológicas, geomorfológicas e geológicas da região.

A escassez hídrica, o tipo de cobertura vegetal e os aspectos climáticos são os principais fatores de influência na dinâmica de mudanças do uso e cobertura da terra na sub-bacia hidrográfica do rio Banabuiú. Os anos de seca compreendidos entre 2012 e 2017, provocados pela interferência do El Niño, geraram consequências para o agronegócio e acarretaram a adoção de estratégias de convivência com o fenômeno da seca. De acordo com Tritsch *et al.* (2023) essa seca provocou um aumento na construção de pequenos açudes individuais que resultaram em uma intensificação da pecuária e um aumento na produção de leite no Sertão Central.

A vegetação presente no bioma caatinga tem uma característica peculiar em comparação com outros biomas em virtude de sua relação com a precipitação. Brito *et al.* (2020) observaram uma sensibilidade da vegetação à sazonalidade da precipitação. O monitoramento da cobertura vegetal foi realizado com os Índices de Vegetação da Diferença Normalizada (NDVI) e o de Vegetação ajustado ao Solo (SAVI), processadas a partir de imagens do Landsat 8.

4 ANÁLISE TEMPORAL DO USO E COBERTURA DA TERRA

4.1 Introdução

O uso e cobertura da terra de uma determinada região é resultado das atividades antropogênicas, refletindo os impactos ambientais das práticas econômicas realizadas no espaço. Dentre as alterações no meio ambiente observadas com as mudanças no uso e cobertura da terra, podem ser citadas como exemplo a perda na biodiversidade, o aumento do risco de inundações, a degradação dos solos e a perda na produtividade primária, além dos impactos nas mudanças climáticas e a deterioração da qualidade das águas superficiais e subterrâneas.

Akdeniz, Sag e Inam (2023) corroboram o que foi dito anteriormente ao afirmarem que a dinâmica de mudanças de uma região constitui um processo complexo e dinâmico que ocorre sob a influência das atividades antropogênicas e naturais, afetando o ecossistema. Compreender então como essas modificações ocorrem é algo de fundamental importância para os gestores no que diz respeito ao planejamento ambiental e ao desenvolvimento sustentável, visando sempre a prevenção e a mitigação de impactos ambientais.

A análise temporal do uso e cobertura da terra tem ganhado cada vez mais destaque na literatura científica. As principais áreas de aplicação são o planejamento urbano, devido à possibilidade de análise da expansão da mancha urbana; o manejo e a conservação dos recursos naturais, com foco na preservação de biomas, e a gestão de bacias hidrográficas (Karimi *et al.*, 2018; Akdeniz; Sag; Inam, 2023; Xu *et al.*, 2022; Mandal; Ghosh; Mukhopadhyay, 2019; Singh; Venkatramanan; Deshmukh, 2022; Xiong *et al.*, 2022; Rasool *et al.*, 2021).

Os trabalhos produzidos por Leta, Demissie e Tränckner (2021), Roushangar *et al.* (2023), Zhang *et al.* (2023), Yang *et al.* (2022), Beshir, Moges e Dananto (2023) e Tajbakhsh, Memarian e Kheyrikhah (2018) são exemplos de pesquisas em que o acompanhamento da evolução histórica ao longo dos anos serviu como instrumento para a gestão de bacias hidrográficas. Com relação ao manejo dos recursos naturais, o sensoriamento remoto orbital se destaca na função da análise da cobertura vegetal, por meio do monitoramento do desmatamento e da degradação ambiental, por exemplo.

As pesquisas mais recentes em que o sensoriamento remoto foi utilizado para análise da cobertura vegetal com objetivo de avaliar o grau de exposição e de degradação do meio ambiente foram desenvolvidas por Ansari e Golabi (2019); Tajbakhsh, Memarian e Kheyrikhah (2018); Hoque *et al.* (2022); Wang *et al.* (2021); Yu *et al.* (2023); Hou *et al.* (2021) e Cunha *et al.* (2021).

De todas as publicações científicas citadas, o trabalho executado no Brasil por Cunha *et al.* (2021) no ecótono Cerrado/Atlântico com base em uma série temporal de 30 anos entre 1986 e 2016 merece destaque. Essa metodologia permitiu o conhecimento dos impactos ambientais do avanço da agricultura na vegetação nativa.

A área de estudo escolhida para o desenvolvimento dessa pesquisa, a sub-bacia hidrográfica do rio Banabuiú, está localizada no Sertão Central Cearense. Em termos de vegetação, essa área de captação compreende ao bioma da Caatinga que, apesar de sua riqueza em biodiversidade, ainda padece de informações e de um monitoramento mais efetivo.

O presente trabalho se encaixa nessa lacuna científica ao propor, por meio de uma série de imagens de satélite correspondente ao período de 2003 a 2022, uma análise temporal do uso e cobertura da terra na sub-bacia hidrográfica do rio Banabuiú. Pretende-se analisar o processo de ocupação do espaço na região, e assim fornecer subsídios para o planejamento ambiental e colaborar para a conservação e preservação dos recursos naturais.

4.2 Procedimentos metodológicos de análise temporal

A análise temporal das mudanças no uso e cobertura da terra foi efetuada como forma de compreender a evolução dos padrões espaciais de ocupação das atividades antrópicas e predizer cenários futuros de ocupação do espaço.

Como já mencionado, para a execução dessa análise foram realizados mapeamentos em três datas distintas, referente aos anos de 2003, 2014 e 2022. Para compor a área de estudo, foram adquiridas cenas do sensor *Operation Land Imager* (OLI) presente nas séries de satélite Landsat 8 e 9 e do *Thematic Mapper* (TM) contido no Landsat 5 em três órbitas/pontos, no período de estiagem entre Junho e Dezembro (Quadro 6). Todos os dados orbitais utilizados foram acessados na plataforma *web* do *Earth Explorer* pertencente ao Serviço Geológico dos Estados Unidos.

Quadro 4 - Características das imagens adquiridas.

Sensor/Satélite	Cenas (<i>Path/Row</i>)	Data
TM / Landsat 5	217/64	26/10/2003
TM / Landsat 5	217/63	26/10/2003
TM / Landsat 5	216/64	03/10/2003
OLI / Landsat 8	217/64	19/09/2013
OLI / Landsat 8	217/63	19/09/2013
OLI / Landsat 8	216/64	19/09/2013
OLI / Landsat 8	217/64	28/09/2022
OLI / Landsat 8	217/63	28/09/2022
OLI / Landsat 9	216/64	29/09/2022
TM / Landsat 5	217/63	26/10/2003
TM / Landsat 5	216/64	03/10/2003

Fonte: elaborado pelo autor.

A escolha dos sensores TM e OLI dos satélites Landsat 5, 8 e 9 se justificou pela disponibilidade gratuita das imagens, resolução espacial de 30 m, tempo de revisita de 16 dias e necessidade de um maior recobrimento temporal, o que permitiu recobrir toda a área de estudo com o menor tempo de processamento dos dados. As fases de processamento das imagens se subdividiram em três etapas: pré-processamento, processamento e pós-processamento.

4.2.1 Pré-processamento

A fase de pré-processamento teve como finalidade preparar a imagem para facilitar a interpretação. As imagens adquiridas passaram pelos métodos do mosaico e empilhamento de bandas, ambos inseridos no *software* QGIS. As bandas escolhidas para o empilhamento foram as pertencentes ao espectro visível do sensoriamento remoto (azul, verde e vermelho) e as faixas do infravermelho próximo e médio.

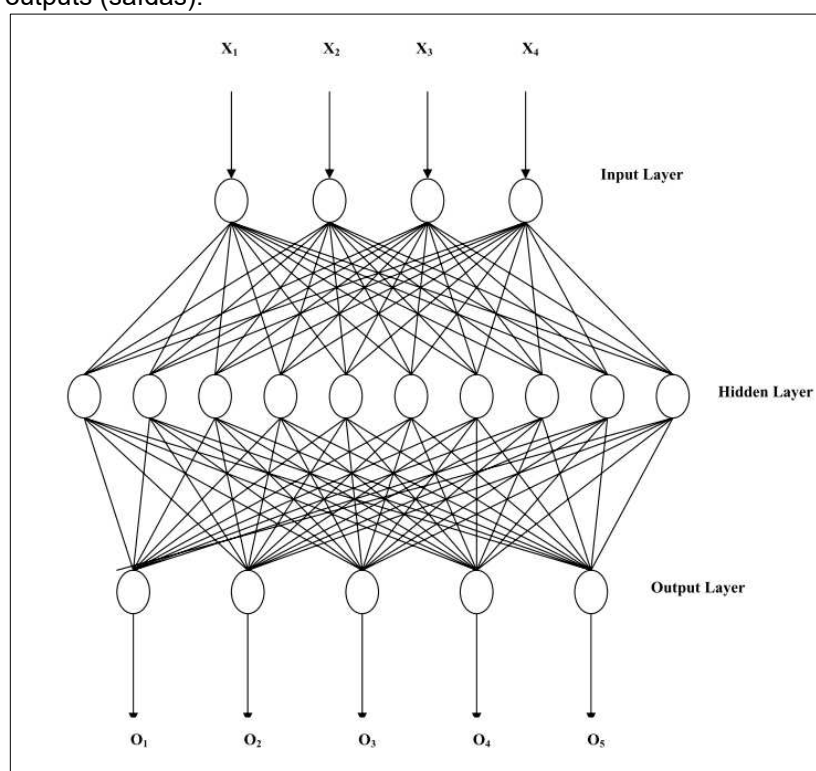
4.2.2 Processamento

Na etapa de processamento foi executada a classificação das imagens de satélite com auxílio da rede neural artificial *Multi Layer Perceptron* através do método *backpropagation*, implementado no *software* Matlab. Nesse algoritmo, “o erro encontrado na camada de saída é retro propagado para a camada oculta para ajustar os pesos sinápticos, até que, pela repetição desse procedimento, o processo de

aprendizagem possa convergir” (Wu *et al.*, 2017, p. 1751).

Foi escolhido para essa pesquisa um modelo com três camadas: a de entrada, a oculta e a de saída. Segundo Pereira e Centeno (2017), a camada de entrada (*input layer*) contém os padrões que são apresentados a rede, a oculta (*hidden layer*) compõe a maior parte do processamento com as conexões ponderadas e a de saída (*output layer*) apresenta o resultado final (Figura 11).

Figura 11 - Estrutura de uma Rede Neural Artificial Multi Layer Perceptron com 4 entradas, 10 neurônios na camada oculta e 5 outputs (saídas).



Fonte: Yuan, Wiele e Khorram (2009, p. 246).

O dado *raster* foi então categorizado nas classes de área urbana, de vegetação natural, de corpo d'água continental, de área descoberta e de agricultura segundo o esquema de classificação apresentado no Quadro 5 com as subclasses contidas em cada categoria


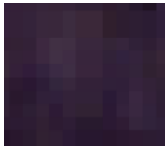



Quadro 5 - Chave de interpretação.

(continua)

Código	Nome	Definição	Representação na imagem
--------	------	-----------	-------------------------

Quadro 5 - Chave de interpretação.

(conclusão)

1	Área urbana	Áreas residenciais, domésticas e industriais.	
2	Vegetação natural	Caatinga arbustiva aberta e densa, Caatinga arbórea, Floresta Caducifólia, Floresta Subcaducifólia e Floresta Subperenifólia (IBGE, 2021).	
3	Corpo d'água continental	Rios, açudes, lagos e todo corpo hídrico continental.	
4	Área descoberta	Solo exposto e áreas de afloramento rochoso.	
5	Agricultura	Áreas ocupadas por agricultura, pastagem ou pousio.	

Fonte: elaborado pelo autor.

As amostras de treinamento foram selecionadas no *software* Qgis Desktop 3.34.11 baseado no conhecimento da classificação supervisionada, em que o usuário possui um conhecimento prévio sobre a região. As amostras foram selecionadas de maneira aleatória através da ferramenta de geração de pontos nos centroides dos *pixels*. No processo de classificação das imagens, foi utilizada uma proporção de 70% para treinamento, 15% para teste e 15% para validação. Essas amostras foram inseridas como *inputs* na camada de entrada através da amostragem das bandas azul, verde, vermelho, infravermelhos próximo e médio, com cinco *outputs* em código binário referente às classes a serem mapeadas.

As métricas adotadas como avaliação foram a Acurácia Global e o Índice Kappa para as amostras de teste, que é um conjunto de dados aplicado para avaliar o desempenho da RNA. A Acurácia Global ou Parcial trata do percentual da área estudada que foi classificado corretamente quando comparado à amostra considerada como referência (Story; Congalton, 1986). Nesse estudo, a acurácia individual foi avaliada em forma de matriz de confusão. O Índice Kappa, segundo Pandey, Kumari e Nawajish (2023), é uma medida de avaliação da exatidão dos resultados da

classificação que varia de 0 a 1 em que 0 representa a inexistência de relação entre a imagem classificada e a de referência e quanto mais próximo de 1 mais perfeito é o ajuste entre as imagens.

4.2.3 Pós-processamento

Após a geração da imagem classificada, foi necessário corrigir os erros de comissão e omissão introduzidos nos produtos gerados. A correção foi realizada com a análise comparativa entre imagens dos sensores TM e OLI em datas diferentes e, no caso da cena mais recente de 2022, com imagens dos satélites Sentinel 2A e 2B. A checagem da veracidade do produto mais recente também foi realizada com visitas de campo e levantamento aerofotogramétrico com uma Aeronave Remotamente Pilotada (ARP) Phantom 3 *Professional* e um DJI AIR 2S.

4.3 Resultados e discussões de análise temporal

4.3.1 Avaliação da acurácia

Nesse tópico, estão apresentados os principais resultados do processo de classificação de imagens, assim como as matrizes de confusão e os parâmetros estatísticos de cada período analisado para entender as dinâmicas de mudanças dos mapas de uso e cobertura da terra. Os melhores resultados das classificações de uso e cobertura da terra para os períodos analisados, atingidos por um método empírico, estão representados na Tabela 3. Os critérios utilizados para escolha da melhor classificação foram a Acurácia Global e o Índice Kappa para as amostras de teste.

Tabela 3 - Definições e resultados da RNA para os usos e coberturas da terra em 2003, 2014 e 2022.

	2003	2014	2022
Nº de <i>inputs</i>	6	6	6
Nº de neurônios na camada oculta	9	9	13
Nº de iterações	5	5	5
Nº de ciclos para convergência	53.134	55.404	59.111
Acurácia Global (amostras de teste)	0,955	0,944	0,936
Índice Kappa (amostras de teste)	0,932	0,925	0,914

Fonte: elaborado pelo autor.

Os valores obtidos para a Acurácia Global e o Índice Kappa foram considerados satisfatórios nos três períodos analisados, o que reflete a boa qualidade de amostras utilizadas no treinamento e o bom desempenho do algoritmo de classificação escolhido. O menor valor obtido na Acurácia Global para as amostras de teste foi superior a 0,936 em 2022. Com relação ao Índice Kappa, as três classificações efetuadas se encontram próximas a um ajuste perfeito por estarem dentro da faixa de referência de 0,81 a 0,99 apresentada por Pandey, Kumari e Nawajish (2023).

A análise das matrizes de confusão para as amostras de teste possibilitou uma compreensão mais completa sobre os erros cometidos durante a fase do processamento, além de ter sido fundamental para nortear a fase de pós-classificação. A matriz de erros de 2003, por exemplo, demonstrou que, nesse ano, as classes mais difíceis de serem distinguidas entre si foram a área urbana e as áreas descobertas (Tabela 4).

Tabela 4 - Matriz de erros de confusão no mapa classificado de 2003 (amostras de teste).

	Área urbana	Vegetação natural	Corpo d'água continental	Área descoberta	Agricultura	Totais classificados	Acurácia do usuário (%)
Área urbana	345	3	0	26	28	402	85,82
Vegetação natural	0	5478	3	10	98	5589	98,01
Corpo d'água continental	0	5	882	0	10	897	98,33
Área descoberta	17	15	1	790	12	835	94,61
Agricultura	21	110	0	22	1542	1695	90,97
Totais de referência	383	5611	886	848	1690	9418	
Acurácia de produção (%)	90,08	97,63	99,55	93,16	91,24		
Acurácia Global (%)	95,95						

Fonte: elaborado pelo autor.

A acurácia do usuário é influenciada diretamente pelos erros de comissão ocorridos no processamento da classificação, ou seja, quando pixels de uma categoria são classificados em outras classes (Story; Congalton, 1986). A semelhança espectral apresentada na Tabela 4 entre as classes de área urbana e das áreas descobertas contribuiu para uma acurácia do usuário menor em relação às outras classes. Em oposição à área urbana, a classe do corpo d'água continental foi a que obteve a maior acurácia do usuário, com 98,33% dos pixels classificados corretamente, pois não se confundiu com outras classes. A acurácia de produção, utilizada para avaliar os erros de omissão cometidos entre as classes, obteve valores acima de 90% para todas as categorias estudadas.

Na matriz de erros de confusão da imagem classificada registrada no ano de 2014, nota-se uma semelhança entre os pixels enquadrados nas categorias de agricultura e de área descoberta (Tabela 5). Essa relação pode ser explicada pela presença de áreas de pousio que foram classificadas como agricultura.

Tabela 5 - Matriz de erros de confusão no mapa classificado de 2014 (amostras de teste).)

	Área urbana	Vegetação natural	Corpo d'água continental	Área descoberta	Agricultura	Totais classificados	Acurácia do usuário (%)
Área urbana	1027	1	1	42	53	1124	91,37
Vegetação natural	0	3771	0	17	125	3913	96,37
Corpo d'água continental	1	1	1309	6	14	1331	98,35
Área descoberta	52	50	0	1354	68	1524	88,84
Agricultura	20	15	5	91	2011	2142	93,88
Totais de referência	1100	3838	1315	1510	2271	1034	
Acurácia de produção (%)	96,36	98,25	99,54	89,67	88,51		
Acurácia Global (%)	94,40						

Fonte: elaborado pelo autor.

A área descoberta foi a que mais apresentou erros de comissão durante o processamento do uso e cobertura da terra em 2014, com uma acurácia do usuário

de 88,84%. A classe da agricultura foi a que apresentou mais erros de omissão na análise da acurácia de produção com 88,51%. Com relação à acurácia global, a classificação para o ano de 2014 obteve 94,40% dos pixels classificados corretamente, o que foi considerado aceitável.

Na matriz de confusão efetuada para o ano de 2022, observou-se uma confusão acentuada entre as classes da agricultura e de áreas descobertas (Tabela 6). Essa semelhança pode ter acontecido pela agricultura familiar ser o tipo predominante de cultivo presente na área de estudo. Como a agricultura familiar é praticada em áreas de menor proporção, a identificação desse tipo de cultivo é mais complexa nas imagens do Landsat 9.

Tabela 6 - Matriz de erros de confusão no mapa classificado de 2022 (amostras de teste).

	Área urbana	Vegetação natural	Corpo d'água continental	Área descoberta	Agricultura	Totais classificados	Acurácia do usuário (%)
Área urbana	989	3	0	57	25	1074	92,09
Vegetação natural	0	2922	0	29	60	3011	97,04
Corpo d'água continental	0	0	704	0	4	708	99,43
Área descoberta	28	5	2	1502	61	1598	93,99
Agricultura	8	48	19	124	836	1035	80,77
Totais de referência	1025	2978	725	1712	986	7426	
Acurácia de produção (%)	96,49	98,12	97,10	87,73	84,79		
Acurácia Global (%)	93,63						

Fonte: elaborado pelo autor.

A imagem classificada de 2022 foi a que mais apresentou erros de comissão entre a agricultura e as áreas descobertas, com uma acurácia individual de 80,77%. Com relação aos erros de omissão, as categorias em que esses erros mais aconteceram foram as áreas descobertas e a agricultura, com acurácias de produção de 87,73% e 87,79%, respectivamente. A acurácia global obtida no processamento foi equivalente a 93,63%, o que foi considerado aceitável.

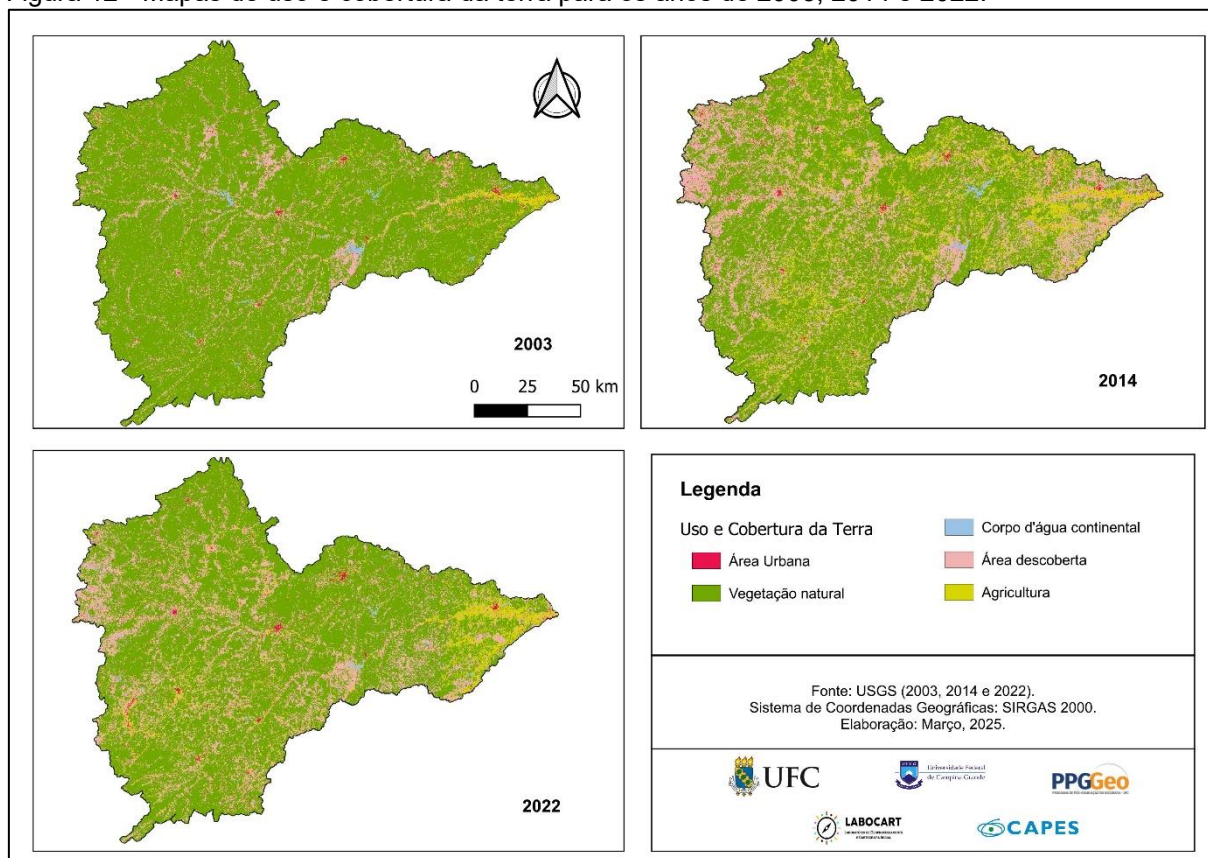
Além dos erros observados nas matrizes de confusão, notou-se na fase de amostragem e pós-processamento das imagens muitas semelhanças espectrais entre a agricultura e a vegetação natural e entre as áreas de pastagem e as áreas descobertas. O tamanho reduzido das parcelas de agricultura contribuiu para a inserção de pixels de agricultura classificados erroneamente como vegetação natural.

Sabe-se que, no sertão central do Ceará, alguns produtores rurais que antes possuíam como principal atividade econômica a agricultura passaram a se dedicar à pecuária, como consequência do período de escassez hídrica que aconteceu entre 2012 e 2017 (Tritsch *et al.*, 2023). Contudo, o aumento em hectares impulsionado pela pecuária não foi observado na classe da agricultura. Uma hipótese para a não visualização desse aumento é uma possível inclusão das áreas de pastagem na classe referente às áreas descobertas em razão do tipo de cobertura vegetal presente nesses locais.

4.3.2 Dinâmica de mudanças no uso e cobertura da terra na sub-bacia do rio Banabuiú (2003-2022).

Os mapas de uso e cobertura da terra produzidos para os anos de 2003, 2014 e 2022 podem ser visualizados na Figura 12 logo abaixo:

Figura 12 - Mapas de uso e cobertura da terra para os anos de 2003, 2014 e 2022.



Fonte: elaborado pelo autor.

Os dados extraídos a partir dos mapas de uso e cobertura da terra evidenciaram um aumento inexpressivo na área urbana entre os anos de 2003 e 2022. Quanto à cobertura vegetal, houve uma redução de 4.219,984 km² entre 2003 e 2014 e um aumento de 1.759,480 km² no período de 2014 e 2022, conforme pode ser deduzido a partir da Tabela 7.

Tabela 7 - Quantitativo de áreas e porcentagem de cada classe de uso e cobertura da terra.

(continua)

	2003		2014		2022		2003 -2022
Classes	Área (km ²)	Porcentagem (%)	Área (km ²)	Porcentagem (%)	Área (Km ²)	Porcentagem (%)	Diferença (%)
Área Urbana	211,16	1,08	212,81	1,09	217,07	1,11	0,03
Vegetação natural	16.095,75	82,07	11.875,77	60,59	13.635,24	69,56	-12,51

Tabela 7 - Quantitativo de áreas e porcentagem de cada classe de uso e cobertura da terra.

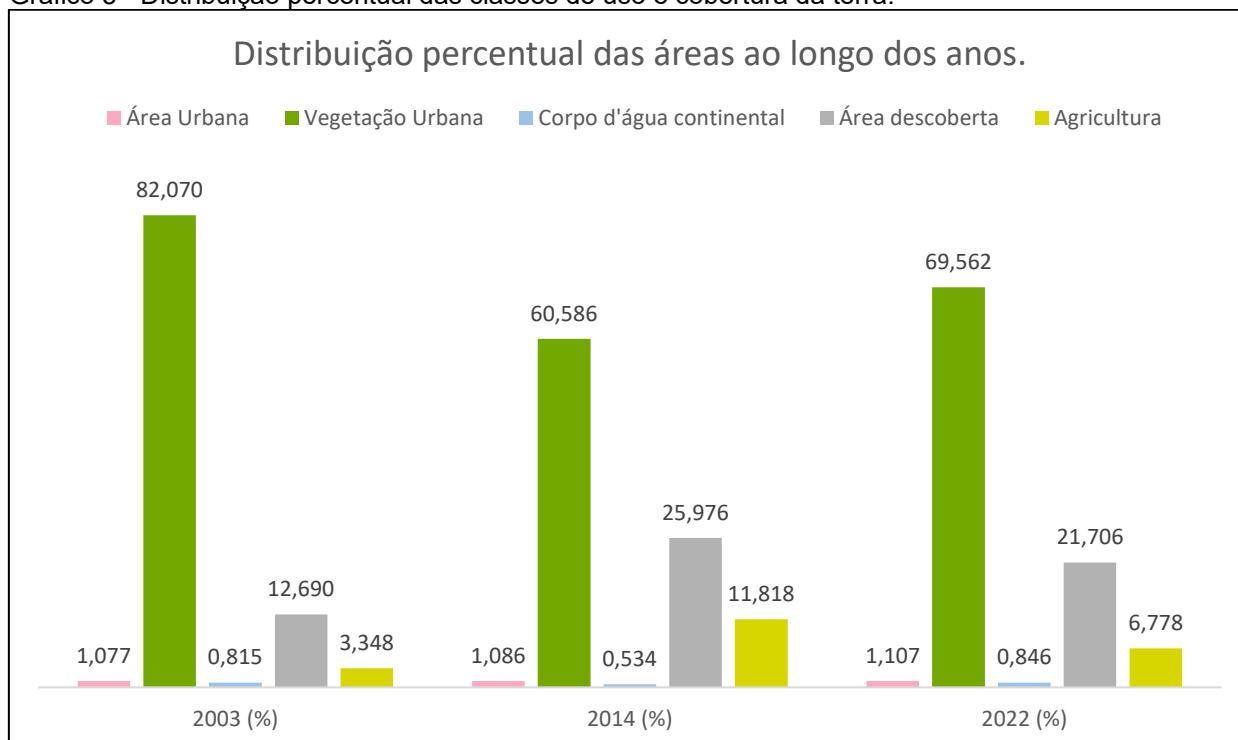
(conclusão)

Corpo d'água	159,86	0,81	104,76	0,53	165,92	0,85	0,04
continental							
Área descoberta	2.488,80	12,69	5.091,67	25,98	4.254,75	21,71	9,02
Agricultura	656,59	3,35	2.316,54	11,82	1.328,56	6,78	3,43

Fonte: elaborado pelo autor.

O Gráfico 05, inserido abaixo, auxilia na interpretação dos resultados apresentados na Tabela 07 ao demonstrar a variação da porcentagem ocupada por cada classe de uso e cobertura da terra ao longo do período de análise (2003 – 2022). As porcentagens de áreas ocupadas por vegetação natural e as áreas descobertas possuem uma relação inversamente proporcional, como ocorre com frequência em outros biomas em virtude de fatores como o desmatamento.

Gráfico 5 - Distribuição percentual das classes de uso e cobertura da terra.



Fonte: elaborado pelo autor.

Porém, no ambiente da Caatinga, além da supressão da vegetação nativa e de prováveis situações de recomposição da cobertura vegetal, a variação expressiva no quantitativo das áreas recobertas pela vegetação natural também pode ser explicada pela característica das plantas caducifólias, que perdem suas folhas durante

os meses mais secos para evitar a perda de água (Ageitec, 2024). Por ter relação direta com a pluviometria, o alvo da vegetação se apresenta com tons semelhantes a uma floresta mais densa em períodos de pluviometria elevada e, em meses de escassez hídrica, essa classe se aproxima do comportamento espectral de um solo desnudo. Corroborando o que foi dito, Silva e Cruz (2018) descrevem as dificuldades técnicas para o mapeamento da Caatinga, sendo a principal delas a sazonalidade na disponibilidade hídrica e a distribuição errática da pluviosidade, o que torna a caracterização da vegetação uma atividade complexa.

As imagens selecionadas para a pesquisa abrangem situações distintas quanto ao total pluviométrico, pois o escopo temporal utilizado foi definido para visualizar os efeitos da escassez hídrica presente no período entre 2012 e 2017 a partir da comparação com as datas antes e após. Para fins explicativos, a Tabela 8 apresenta os totais precipitados registrados em cinco postos pluviométricos distribuídos na área de estudo entre os meses de Janeiro e Maio nos anos de 2003, 2014 e 2022, disponibilizados na plataforma *online* da Funceme.

Tabela 8 - Índice pluviométrico entre Janeiro e Maio nos anos de 2003, 2014 e 2022.

Postos Pluviométricos	Índice pluviométrico entre Janeiro e Maio (mm)			Média pluviométrica (mm)
	2003	2014	2022	2003 - 2022
Banabuiú	618,7	567,4	633,4	606,5
Boa Viagem	494	304,9	464	420,97
Morada Nova	632,5	509,6	916,7	686,27
Quixadá	709,8	490	856,6	685,47
Quixeramobim	479,7	368,4	536,3	461,47

Fonte: Funceme (2024).

Com relação à área dos espelhos d'água, a Tabela 7 demonstra que houve uma redução de 55,95 km² entre os anos de 2003 e 2014 e foi observado um aumento de 61,155 km² no mapa de uso e cobertura da terra de 2022. O aumento observado no mapa de uso e cobertura da terra desse último ano pode ser creditado como uma consequência da construção de pequenos açudes que foram concebidos como estratégias de convivência com a seca. O açude da Cachoeira do Germano, localizado no Vale do Forquilha em Quixeramobim, que foi finalizado em 2012, é um exemplo de um açude que foi construído durante o período de análise da pesquisa para complementar o sistema de abastecimento de água do Vale do Forquilha e de

municípios próximos, como Pedra Branca – CE (Figura 13).

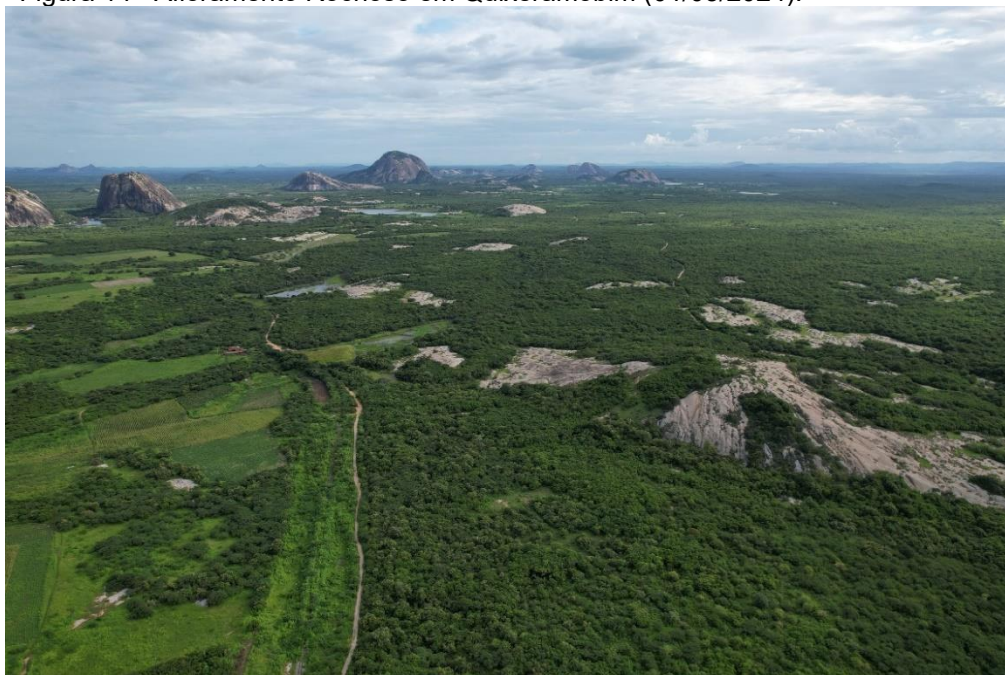
Figura 13 - Açude da Cachoeira do Germano, Vale do Forquilha, Quixeramobim, Ceará (02/05/2014).



Fonte: acervo pessoal.

Com relação às áreas descobertas, houve um aumento de 2602,867 km² entre 2003 e 2014, com uma de redução de 836,918 km² entre 2014 e 2022, como apontado na Tabela 7. As áreas de Afloramento Rochoso (Figura 14), muito presentes na área estudada, foram enquadradas nessa categoria em virtude da semelhança espectral com os solos desnudos nas imagens do satélite Landsat.

Figura 14 - Afloramento Rochoso em Quixeramobim (01/05/2024).



Fonte: acervo pessoal.

As áreas de agricultura aumentaram em 1659,951 km² entre 2003 e 2014, com uma redução de 987,982 km² no período seguinte, conforme informações apresentadas na Tabela 7. Dados obtidos pela Funceme e divulgados por Tritsch *et al.* (2023) indicaram um decaimento nas áreas irrigadas da sub-bacia hidrográfica do rio Banabuiú de 13.000 ha para 5.000 ha entre 2012 e 2018.

Nota-se na área de estudo a presença expressiva da categoria referente à vegetação natural em comparação com a área urbana. A formação vegetal natural está presente em mais de 69% da área estudada, enquanto a área urbana ocupa aproximadamente 1% do local, valor que foi próximo ao encontrado por Lima e Silva (2018).

A região inserida no Perímetro Irrigado de Morada Nova foi o local que apresentou a predominância de atividades agropecuárias na sub-bacia hidrográfica do rio Banabuiú. A carcinicultura é a principal atividade desenvolvida no Perímetro, seguida pelo cultivo de grãos, como arroz e feijão, e de frutas, como banana, graviola, acerola e coco, além da criação de gado para corte e produção de leite, conforme relata o Departamento Nacional de Obras Contra às Secas (DNOCS, 2021).

Essas informações foram verificadas em campo com imagens de um Remotely Piloted Aircraft System, Phantom 3 Professional, no dia sete de setembro

de 2023, que podem ser vistas na Figura 15.

Figura 15 - Reconhecimento de campo no Perímetro Irrigado de Morada Nova (07/09/2023).



Fonte: acervo pessoal.

Além dos cultivos já citados, há uma presença expressiva da agricultura familiar com cultivos plantados durante o período chuvoso, entre fevereiro e maio, como milho, feijão, palma, sorgo, entre outros. A Figura 16 apresenta um cultivo milho em Quixeramobim.

Figura 16 - Cultivo de milho em Quixeramobim (02/05/2023).



Fonte: acervo pessoal.

O Açude de Banabuiú, um dos principais açudes da área de estudo, foi visitado para fins de reconhecimento de campo em sete de setembro de 2023. Observou-se no local um canteiro de obras nas imediações da área de captação (Figura 17). Estão sendo executadas no local obras para recuperação e modernização da barragem Banabuiú.

Figura 17 - Registro de campo no Açude Banabuiú (08/09/2023).



Fonte: acervo pessoal.

No Açude de Quixeramobim, foi visto em oito de setembro de 2023 que o corpo estava em estado de eutrofização a jusante da barragem de Quixeramobim,

além de estar com a lâmina d'água abaixo do ideal. Na segunda visita de campo, em maio de 2024, a situação encontrada era bastante diferente do que foi visto no período seco, uma vez que o reservatório atingiu a sua capacidade máxima. A Figura 18 apresenta o comparativo entre as duas situações observadas.

Figura 18 - Visitas de campo no Açude de Quixeramobim realizadas no dia 08/09/2023 e 01/05/2023.



Fonte: acervo pessoal.

Algumas pesquisas se propuseram a identificar os diversos tipos de caatinga inseridos na área de captação. Lima e Silva (2018) elaboraram um mapa de vulnerabilidade natural à vegetação e identificaram uma presença relevante dos tipos de caatinga arbustiva aberta e densa, somando 58,15% da sub-bacia hidrográfica do rio Banabuiú, valor próximo aos 69,56% de vegetação nativa observado no mapa de uso e cobertura da terra em 2022. Esses mapeamentos ressaltaram o resultado produzido pelo *Caderno regional da sub-bacia do Banabuiú* (Ceará, 2009) que afirmaram que os terrenos da sub-bacia hidrográfica do rio Banabuiú são revestidos predominantemente por caatinga degradada.

Recentemente, Lima *et al.* (2024) publicaram uma análise estatística das classes de uso e cobertura da terra em Quixeramobim, município contido na área estudada. Com base nos dados do projeto MapBiomias, referente ao período de 1985 a 2022, a pesquisa identificou uma redução no total classificado como corpo d'água de 54,84%, enquanto a área ocupada por floresta aumentou em 8,3% e a por agropecuária reduziu em 13,12%. Os pesquisadores observaram uma correlação estatística positiva entre as classes da agropecuária e corpo d'água, relação que também foi identificada pela presente pesquisa na sub-bacia hidrográfica do rio Banabuiú.

Tritsch *et al.* (2023) auxiliam na compreensão da justificativa dessa relação

em seu estudo sobre a relação da água, agricultura e da vegetação nativa no Sertão Central do Ceará. Os autores identificaram uma intensificação da pecuária leiteira em contraste com a agricultura na área de estudo durante a seca de 2012 a 2018, o que resultou na construção de pequenos açudes individuais próximos às áreas de pastagem. A Figura 19 inserida logo abaixo mostra uma área de pasto observada na área de captação próxima a um pequeno açude.

Figura 19 - Áreas de pasto próximas a pequenos açudes (02/05/2023).



Fonte: acervo próprio.

4.4 Considerações finais

A análise temporal de uso e cobertura da terra realizada na sub-bacia hidrográfica do rio Banabuiú observou uma tendência de redução e recomposição da cobertura vegetal da caatinga. Isso tem como hipóteses, além do desmatamento, a diferença entre os índices pluviométricos anuais nas imagens selecionadas, assim como as limitações técnicas do uso da classificação supervisionada de imagens em imagens de média resolução espacial, como as provenientes da série do Landsat, aplicadas ao bioma Caatinga no período analisado.

Em relação à área urbana, especificamente, foram observados alguns erros de comissão, em que pixels pertencentes à classe de área descoberta foram

classificados erroneamente como área urbana. Esses erros foram corrigidos em sua grande maioria no momento da pós-classificação.

Quanto à área ocupada pelos corpos hídricos, observou-se um aumento no percentual ocupado por essa classe entre os anos de 2014 e 2022, o que foi creditado ao aumento na construção de pequenos açudes próximos a áreas de pecuária leiteira (Tritsch *et al.*, 2023). Tritsch *et al.* (2023) identificaram em Quixeramobim, município pertencente a área de estudo, um aumento da pecuária leiteira em comparação com a agricultura entre 2012 e 2018. Em decorrência, observou-se o crescimento de pequenos açudes no entorno de áreas de pastagens.

Durante o período compreendido entre 2003 e 2014, foi observada uma estabilidade no total nas áreas agrícolas seguido por uma redução no quantitativo de áreas na fase seguinte. Ocorreu também uma confusão entre essa classe e a vegetação nativa.

A presença das atividades agropecuárias predomina na região do Perímetro Irrigado de Morada Nova, que é irrigado pelo rio Banabuiú, sendo a carcinicultura a principal atividade desenvolvida no local. Constatou-se também o aumento da pecuária leiteira na área estudada em contraste com a redução nas atividades agrícolas.

5 MODELAGEM DO USO E COBERTURA DA TERRA

5.1 Introdução

Quando aplicado aos processos ambientais, os modelos computacionais podem representar o que acontece no ambiente através de um molde conceitual baseado em dados reais observados, sendo muito utilizados na análise dos fenômenos naturais aliado aos fatores antrópicos (Piga, 2017). Segundo Barnsley (2007), modelos ambientais têm sido desenvolvidos para representar elementos como os aspectos climáticos, hidrológicos além dos serviços ecossistêmicos e dos ciclos biogeoquímicos. Ao fornecer uma visão mais ampla e integrada dos sistemas ambientais, esses arquétipos matemáticos ou computacionais podem contribuir de forma efetiva com a resolução de problemas e a tomada de decisão por parte dos gestores públicos.

Os modelos computacionais têm sido aplicados em uma diversidade de estudos ambientais. Alguns exemplos recentes da utilização desses protótipos são as publicações produzidas por Araújo, Ribeiro e Braga (2019), Santana (2020) e Sobczak, Borges e Vaz (2019). Araújo, Ribeiro e Braga (2019) desenvolveram um modelo de alocação da água integrado a um sistema de indicadores ambientais no semiárido. Santana (2020) desenvolveu um modelo baseado no Processo Analítico Hierárquico na previsão de áreas susceptíveis a escorregamento no Recife (PE). Sobczak, Borges e Vaz (2019) utilizaram um modelo de dinâmica de sistemas para analisar os cenários do potencial de biogás no Brasil.

Além disso, no contexto do sensoriamento remoto, os dados orbitais, além de servirem como base para análises ambientais, são peças fundamentais em sistemas de suporte a decisão. Lopes *et al.* (2014) elaboraram um modelo de qualidade das águas com o sensoriamento remoto hiperespectral. Aranha *et al.* (2022) avaliaram a concentração de clorofila-a utilizando imagens do Sentinel 2 em uma região semiárida. Freitas e Araki (2021) simularam a expansão urbana em Curitiba (PR) com o uso de Autômatos Celulares e imagens dos satélites Landsat 5 e 8, provando a eficiência dessa ferramenta na previsibilidade de cenários futuros.

O avanço da aprendizagem de máquinas no reconhecimento de padrões popularizou o conceito da previsibilidade nessa área de conhecimento, abrindo com isso um leque de possibilidades em diversas áreas de aplicações, como a simulação

de áreas de inundação, de susceptibilidade a erosão e o monitoramento do uso e cobertura da terra. Uma vez que as mudanças na ocupação do espaço são produtos das atividades econômicas realizadas pelos indivíduos e que essas alterações possuem uma relação de causa e efeito com a geração de impactos ambientais, o processo de modelagem dessas modificações é capaz de fornecer informações importantes para o planejamento ambiental, como auxílio aos programas de conservação e preservação da cobertura vegetal, e de subsidiar análises de degradação ambiental.

Em ambientes semiáridos, a análise de cenários futuros de uso e cobertura da terra pode ser muito importante na investigação das estratégias de convivência com a seca e na prevenção de impactos ambientais. Nesse momento, é importante frisar que a área escolhida e referida nos capítulos anteriores, a sub-bacia hidrográfica do rio Banabuiú, abrange a região do estado mais susceptível à semiaridez. Durante o período compreendido entre 2012 e 2017, a localidade passou por um grave período de escassez hídrica. Em janeiro de 2017, dois dos principais reservatórios da área de captação, Banabuiú e Quixeramobim, estiveram com 0,55% e 0% da sua capacidade, segundo dados do Portal Hidrológico do Ceará obtidos em 2024.

O fato de a área de captação do rio Banabuiú estar contida no bioma da Caatinga foi justamente um dos maiores desafios para execução dessa pesquisa. A Caatinga ocupa uma área equivalente a 11% do território brasileiro e, apesar da sua riqueza em biodiversidade, tem sido desmatada de forma acelerada principalmente devido ao consumo de lenha nativa, e a transição para pastagens e agricultura (Brasil, 2024). Segundo Moro *et al.* (2024), esse Bioma é predominantemente compreendido por um clima semiárido e uma vegetação caducifólia. Como demonstrado em análise no capítulo anterior, essa característica caducifólia da flora local é o fator de maior complexidade para o desenvolvimento de estudos com sensoriamento remoto, em especial estudos que envolvem a modelagem baseada na previsibilidade dos dados orbitais. Isso se dá uma vez que, durante os períodos de estiagem, a vegetação apresenta um comportamento espectral semelhante a áreas com baixa cobertura vegetal, o que pode dar a falsa impressão de supressão da cobertura vegetal. Na escolha do escopo temporal adotado por essa pesquisa (2003-2022), sabe-se que esse fenômeno foi responsável por provocar algumas mudanças no relacionamento entre os produtores locais e o espaço.

Pensando na área pesquisada, a inclusão dos fatores socioeconômicos e

ambientais mais significativos para a problemática em análise agrega precisão aos resultados produzidos pelo modelo CA-Markov. Dados pedológicos, geológicos, de elevação e de distância das áreas agrícolas e das áreas urbanizadas são capazes de prover um conhecimento mais detalhado a respeito da área analisada. No caso do *software* PLUS (Patch-generation Land Use Simulation Model V1.4), utilizado nessa pesquisa, esses critérios são incluídos na fase da definição da Estratégia de Análise e Expansão da Terra como fatores determinantes para execução dos dados de desenvolvimento potencial, essencial para a simulação do cenário de uso e cobertura da terra.

Assim, objetivou-se modelar a dinâmica das mudanças de uso e cobertura da terra na sub-bacia hidrográfica do rio Banabuiú no período de 2003 a 2014, para simular o cenário futuro de 2022 e validar ou não o modelo CA-Markov, utilizado como método de predição.

5.2 Procedimentos metodológicos

O processo de modelagem da dinâmica de mudanças de uso e cobertura da terra se resume em utilizar duas imagens no tempo $t-1$ e t para simular um cenário em $t+1$. Nessa pesquisa, foram utilizadas as cenas de 2003 e 2022 para simular e validar o modelo em uma comparação com a imagem de 2022. Para atingir esse fim, algumas etapas devem ser seguidas como a classificação das imagens de satélite; a criação do mapa de expansão da terra (*Extract Land Expansion*); a definição dos principais fatores de força responsáveis pelas transições das classes de uso e cobertura da terra; a análise de estratégia de expansão da terra (*Land Expansion Analysis Strategy – LEAS*); a simulação do cenário atual (*CA based on Multiple Random Seeds – CARS*) e a validação dos resultados (*Validation*). A previsão dos cenários futuros foi realizada após a confirmação do bom ajuste entre o dado observado, conhecido como verdade terrestre, e o dado produzido na fase de simulação.

5.2.1 Classificação das imagens de satélite

A etapa da classificação das imagens de satélite foi descrita em detalhes anteriormente no capítulo 4, que explica sobre a análise temporal do uso e cobertura

da terra na sub-bacia hidrográfica do rio Banabuiú. O escopo temporal adotado na pesquisa foi o período compreendido entre 2003 e 2022.

As imagens escolhidas para essa pesquisa pertencem aos sensores TM e OLI inseridos nos satélites Landsat 5, 8 e 9. Os dados orbitais foram coletados no período seco em outubro de 2003, setembro de 2013 e setembro de 2022, para que todas as cenas possuíssem características semelhantes. Faz-se necessário lembrar que o reconhecimento de padrões de imagem foi feito utilizando a base conceitual da classificação supervisionada com o método da Rede Neural Artificial *Multi Layer Perceptron* através do método *backpropagation*, implementado no *software* Matlab. Por fim, os produtos resultantes da classificação das imagens foram corrigidos e validados com informações de campo em um processo conhecido como Pós-Classificação.

5.2.2 Mapa de expansão da terra (*Extract Land Expansion*)

O mapa de expansão da terra é executado para auxiliar o *software* no aprendizado dos padrões de crescimento entre as classes de uso e cobertura da terra durante o período estudado. Foram utilizados como dados de entrada os dados de uso e cobertura da terra nas datas inicial (2003) e final (2022).

5.2.3 Definição dos fatores de força

A definição do conjunto de aspectos utilizados como variáveis explicativas para transição das classes de uso e cobertura da terra é de fundamental importância para um bom ajuste da modelagem. Esses critérios podem ser de natureza física ou socioeconômica e são os aspectos que, na visão do pesquisador, conseguem explicar de forma mais contundente a expansão ou declínio na área ocupada por cada categoria de uso e cobertura da terra. A escolha dos melhores parâmetros é feita através da análise das contribuições de cada fator gerados ao fim de cada execução do *Land Expansion Analysis Strategy* no *software* PLUS. Além das contribuições, o Erro Médio Quadrático também é utilizado como parâmetro de avaliação. Deve-se atentar para que todas as variáveis escolhidas estejam no mesmo formato de dados e sistema de projeção e uma proporção equivalente de linhas e colunas.

5.2.4 Análise de estratégia de expansão da terra (*Land Expansion Analysis Strategy – LEAS*)

No módulo sobre a análise de estratégia de expansão da terra, os dados referentes ao mapa de expansão da terra e os fatores de força que foram definidos anteriormente são utilizados como dados de entrada para geração dos dados *raster* de desenvolvimento potencial para cada classe de uso e cobertura da terra. Esses mapas foram utilizados como variáveis no passo seguinte do modelo preditivo para indicar ao *software* as possíveis áreas de crescimento de cada categoria analisada – por meio do método *Random Forest Regression* (RFR). Vale ressaltar que o Random Forest é um algoritmo de predição de dados que se baseia em um conjunto de árvores de decisão e, por isso, quando o método se baseia em uma estrutura de regressão – caso da RFR - o resultado é alcançado com a média dos valores preditos de árvores de decisão (Breiman, 2001; Rasaei; Bogaert, 2019)

5.2.5 CA based on Multiple Random Seeds - CARS

Nessa etapa ocorre a simulação do cenário de uso e cobertura da terra referente ao último ano do período estudado. É nessa fase que o *software* PLUS processa dinamicamente as mudanças espaciais, as curvas e os valores nas categorias de uso e cobertura da terra. O PLUS finaliza e salva a simulação quando a área alocada se equipara à área demandada (Liang et al., 2021).

Foram utilizados como dados de entrada o *raster* inicial de uso e cobertura da terra relativo ao ano de 2003 e os arquivos de desenvolvimento potencial relativo a cada classe. A configuração desse módulo inclui a definição dos parâmetros dos Neighborhood Weights, da Matriz de Transição e dos Land Demands. Os Neighborhood Weights são calculados com o mapa de expansão da terra. A proporção é encontrada a partir da razão entre a área ocupada por cada categoria e a área total do mapa. A Matriz de Transição permite ao usuário inserir o seu conhecimento sobre a região ao indicar quais transições são prováveis ou não de ocorrer. As colunas da Matriz indicam as atuais classes e as linhas representam as classes futuras. Por fim, os *land demands* são equivalentes à quantidade de *pixels* ocupada por cada classe no último ano de análise, ou seja, 2022.

5.2.6 Validação dos resultados (Validation)

A etapa de validação dos resultados é essencial para o conhecimento de se é possível prosseguir ou não com a predição dos resultados. Nessa fase, o *raster* de uso e cobertura da terra simulado é comparado ao mapa considerado como verdade de terrestre. As métricas de avaliação utilizadas foram o Coeficiente *Kappa*, a Acurácia Global, Acurácia de Produção e do Usuário.

O Coeficiente *Kappa* varia de 0 a 1 e, quanto mais próximo de 1, melhor é o resultado da modelagem. Considera-se um bom ajuste, segundo Pandey, Kumari e Nawajish (2023), quando o valor encontrado para o Índice Kappa está acima de 0,6, valor que se localiza na faixa de um acordo substancial. Recomenda-se também que a acurácia global esteja acima de 0,6.

5.2.7 Demand Prediction

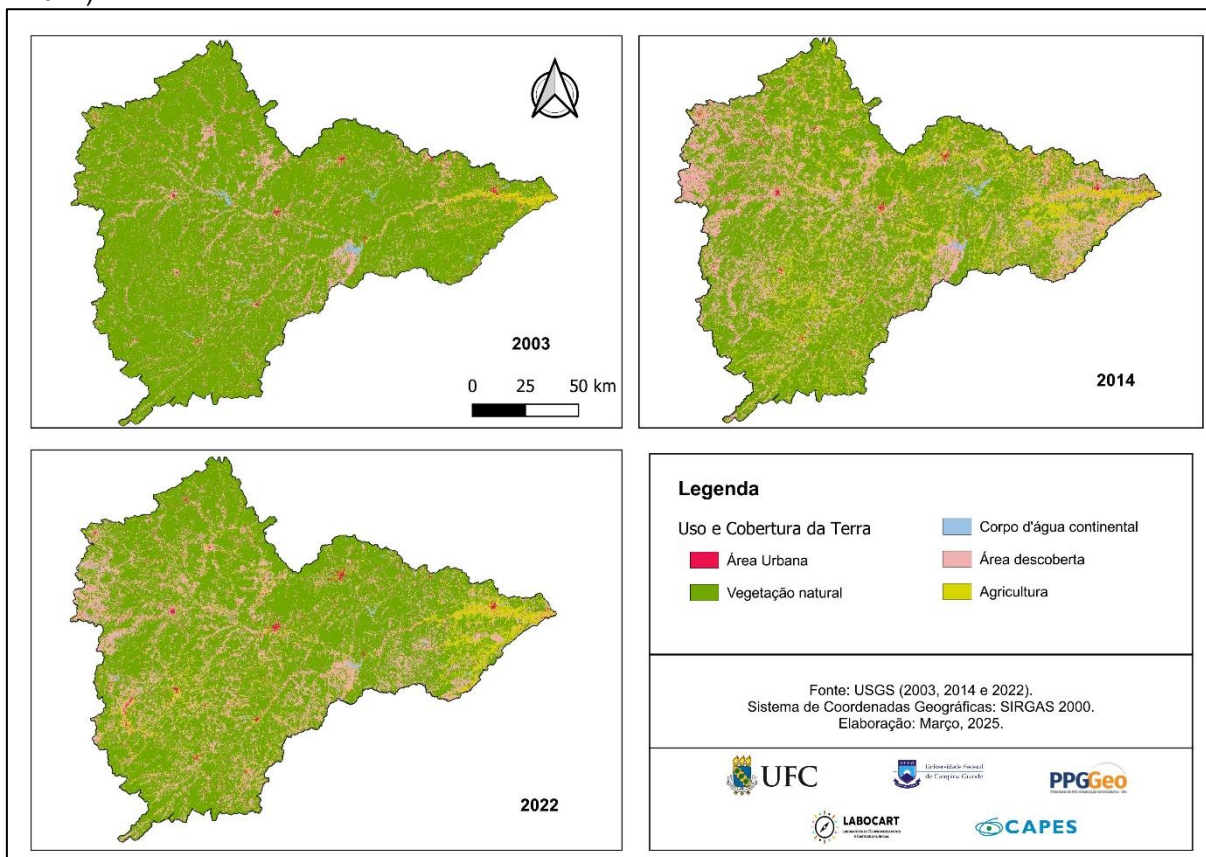
O último passo da metodologia foi a predição do cenário de 2022 com o método preditivo da Cadeia de Markov baseado nos parâmetros obtidos na simulação das mudanças ocorridas na sub-bacia hidrográfica do rio Banabuiú no período entre 2003 e 2022, com posterior comparação com o cenário simulado com o método CARS.

5.3 Resultados e discussões

5.3.1 Mapas de Expansão da Terra

Os mapas de uso e cobertura da terra resultantes do procedimento de classificação de imagens foram apresentados e discutidos em um nível maior de detalhe no capítulo anterior, “Análise Temporal do Uso e Cobertura da Terra”. Para fins didáticos, esse mapa com os três dados de uso e cobertura da terra (2003, 2014 e 2022) será reapresentado aqui (Figura 20).

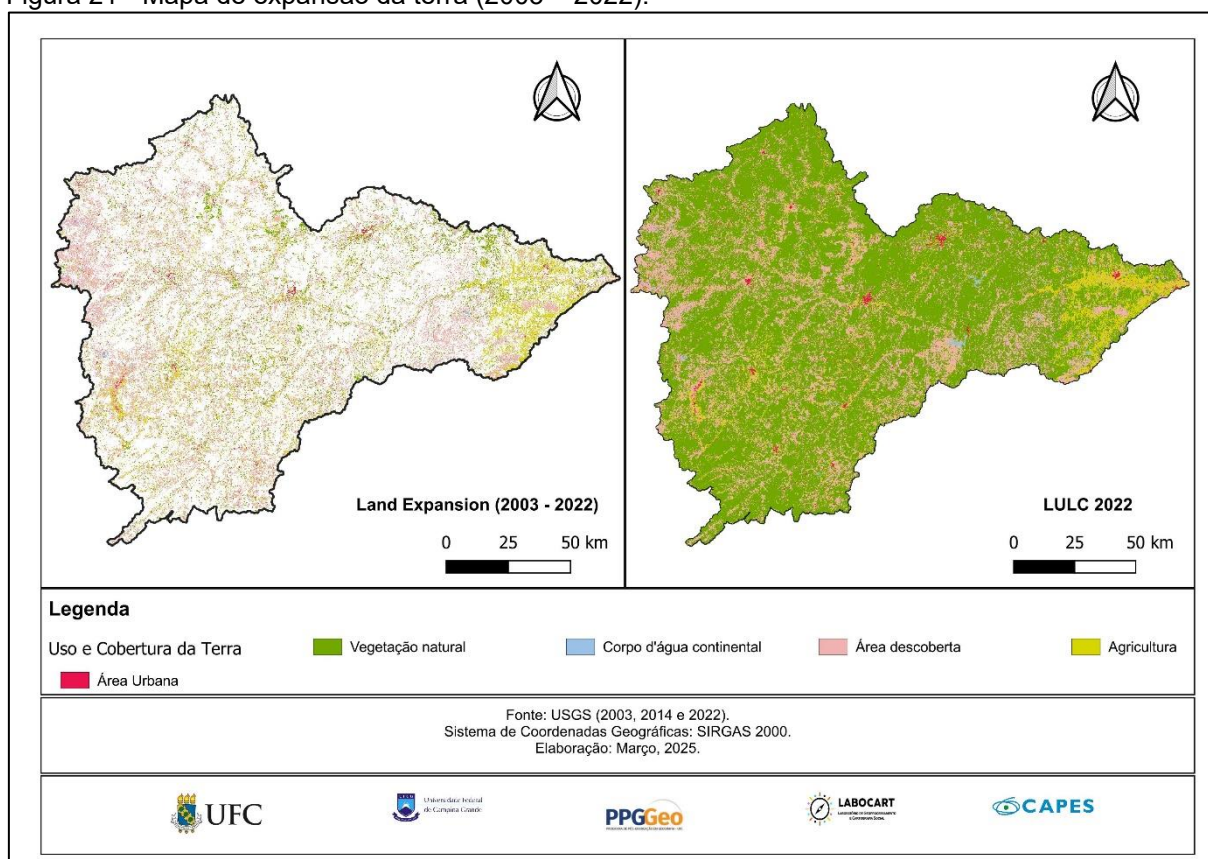
Figura 20 - Mapas de uso e cobertura da terra da sub-bacia hidrográfica do rio Banabuiú (2003, 2014 e 2022).



Fonte: elaborado pelo autor.

O mapa de Expansão da Terra foi executado no período entre 2003 e 2022 e mostrou a evolução das classes de uso e cobertura da terra ao longo dessas datas. O mapa revelou um aumento nas áreas descobertas nesse período (Figura 21).

Figura 21 - Mapa de expansão da terra (2003 – 2022).



Fonte: elaborado pelo autor.

O cenário do mapa de expansão da terra representou a realidade observada nas imagens dos satélites Landsat 5, 8 e 9 adquiridas para a análise de uso e cobertura da terra. A expansão das áreas descobertas no período entre 2003 e 2022 vista na Figura 21 pode ser justificado pelo decréscimo na vegetação nativa provocado pela escassez hídrica.

5.3.2 Definição dos fatores de força

Os fatores de força foram escolhidos de forma empírica e com base na literatura científica (Liang *et al.*, 2021; Bacani *et al.*, 2024; Wang *et al.*, 2022; Cheng *et al.*, 2023). A análise desses fatores ou variáveis explicativas é realizada com base na análise das contribuições das variáveis em cada categoria de uso e cobertura da terra. Dessa maneira, as variáveis escolhidas como explicativas das mudanças no uso e cobertura da terra na sub-bacia hidrográfica do rio Banabuiú foram: declividade, distância das áreas agrícolas (DistAgr), distância dos corpos hídricos (DistAgua), distância das rodovias (DistRodovias), distância das áreas urbanas (DistUrb) e

pedologia.

As contribuições das variáveis (Contrib.) e os ruídos ao longo do tempo dos Erros Médios Quadráticos (RMSE) relativos a cada categoria de uso e cobertura da terra na faixa temporal adotada estão apresentadas na Tabela 9.

Tabela 9 - Contribuição dos fatores de força na escala de tempo (2003-2022).

	Área Urbana		Vegetação Natural		Corpo d'água continental		Área descoberta		Agricultura	
	Contrib.	RMSE	Contrib.	RMSE	Contrib.	RMSE	Contrib.	RMSE	Contrib.	RMSE
Declividade	0.162	0.157	0.185	0.393	0.315	0.248	0.180	0.471	0.187	0.386
DistAgr	0.105	0.123	0.173	0.377	0.110	0.117	0.175	0.464	0.161	0.352
DistAgua	0.152	0.150	0.175	0.380	0.308	0.243	0.185	0.481	0.165	0.358
DistRodovias	0.142	0.144	0.136	0.328	0.088	0.103	0.138	0.403	0.140	0.325
DistUrb	0.308	0.243	0.172	0.374	0.096	0.108	0.167	0.451	0.159	0.350
Pedologia	0.131	0.138	0.159	0.358	0.081	0.099	0.155	0.431	0.186	0.385

Fonte: elaborado pelo autor.

Os resultados das métricas sobre as contribuições dos fatores de força foram coerentes com a realidade em alguns aspectos. na categoria de área urbana a variável explicativa mais representativa em sua expansão foi a distância das áreas urbanas, com uma contribuição de 0,308. A vegetação natural não possui aspectos tão relevantes que possam explicar sua expansão. entre todas as opções, a declividade foi o fator que mais se destacou na proporção de áreas ocupadas por vegetação nativa com 0,185.

Os corpos hídricos demonstraram forte dependência com a variável referente a declividade e distância das áreas ocupadas por corpos hídricos. na prática, isso significa que a declividade é um fator decisivo para a criação de novos açudes e que as áreas ocupadas por corpos hídricos tendem a aumentar próximo de outros corpos d'água continentais.

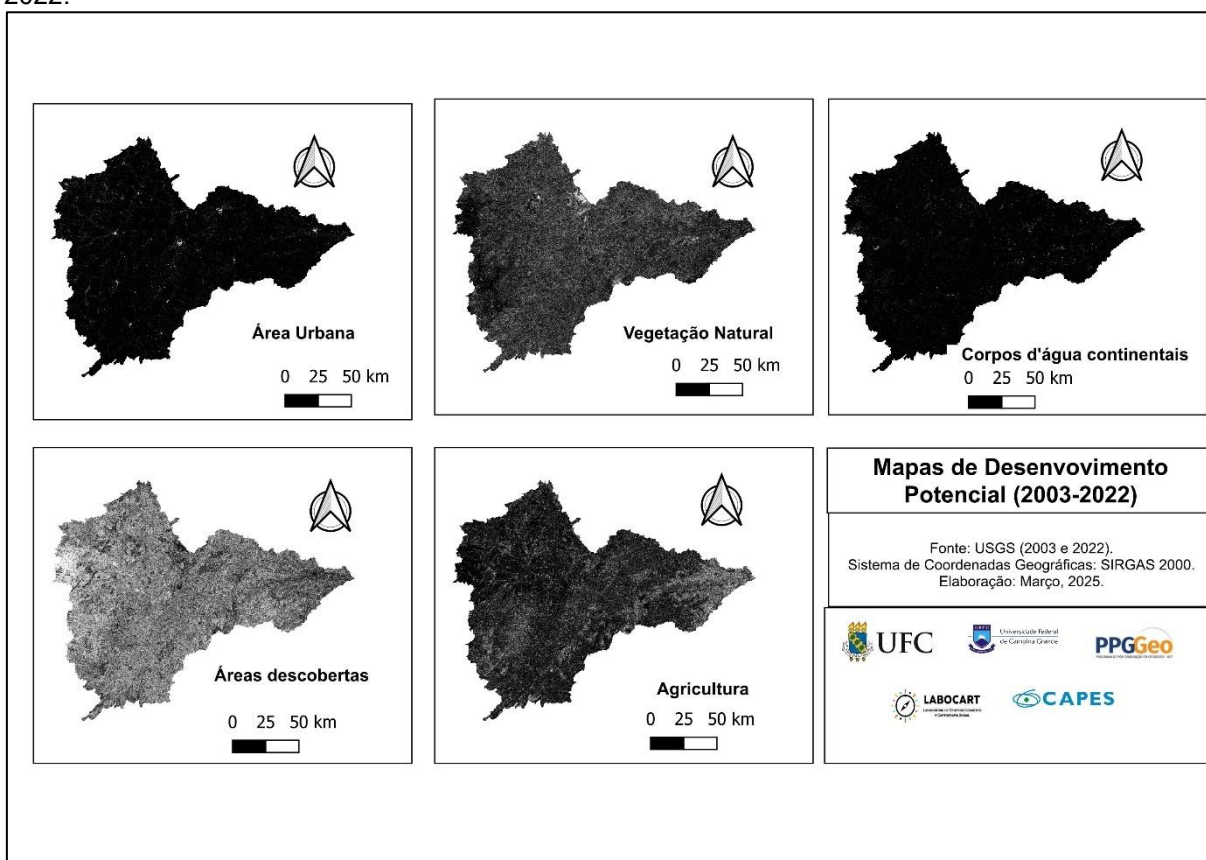
As áreas descobertas seguem um padrão semelhante ao da vegetação natural, sem um aspecto que se sobressaia tanto em relação aos outros. Diferente das outras categorias de uso e cobertura da terra, as áreas descobertas apresentaram diferentes fatores relevantes em cada faixa temporal estudada. O aspecto que demonstrou mais relevância nas alterações das áreas descobertas foi a distância dos corpos hídricos com uma contribuição equivalente a 0,185. A relação entre a distância das áreas urbanas e as áreas descobertas também é uma situação que ocorre na

realidade, uma vez que é comum que as áreas descobertas se transformem em áreas urbanas. Com relação à classe ocupada pela agricultura, os fatores de força mais relevantes foram a declividade e a pedologia.

5.3.3 Análise de Estratégia de Expansão da Terra (Land Expansion Analysis Strategy – LEAS)

A análise de Estratégia de Expansão da Terra gerou como saída, com auxílio do método *Random Forest Regression*, mapas de desenvolvimento potencial produzidos para cada tipo de uso e cobertura da terra na escala temporal. Na Figura 22, anexada logo abaixo, é possível visualizar os mapas referentes à faixa temporal de 2003 a 2022. As partes mais claras dos mapas indicam os locais com maior potencial de crescimento de cada categoria de estudo.

Figura 22 - Mapas de desenvolvimento potencial para cada classe de uso e cobertura da terra 2003 – 2022.



Fonte: elaborado pelo autor.

Percebe-se uma predominância de áreas descobertas no período entre

2003 e 2022. Foram utilizados os mesmos parâmetros para elaboração dos mapas de desenvolvimento potencial. O número de árvores de regressão foi equivalente a 20, com uma taxa de amostragem igual a 0,01.

5.3.4 CA based on Multiple Random Seeds – CARS

A configuração dos parâmetros para execução da simulação de uso e cobertura da terra no módulo CARS pode ser visualizado no Quadro 06.

Quadro 6 - Configuração dos parâmetros no módulo CARS.

<i>Neighborhood Size</i>	3
<i>Thread</i>	1
<i>Pach Generation Threshold</i>	0,2
<i>Expansion Coefficient</i>	0,1
<i>Percentage of seeds</i>	0,1

Fonte: elaborado pelo autor.

O *Land Use Demand*, ou simplesmente a quantidade futura de pixels, foi executado tendo como referência o dado observado de 2022, conforme pode ser vista na Tabela 10.

Tabela 10 - Land Use Demand (2022).

		Área (m²)	Área (%)	Qtde de pixels
1	Área Urbana	21.689.554	1,11	240.995,05
2	Vegetação Natural	1.364.342.362	69,56	15.159.359,58
3	Corpo d'água continental	16.638.759	0,85	184.875,10
4	Área descoberta	425.685.206	21,70	4.729.835,62
5	Agricultura	132.949.187	6,78	1.477.213,19

Fonte: elaborado pelo autor

Os *Neighborhood Weights*, necessários para a execução do modelo preditivo, foram extraídos do mapa de expansão da terra. O cálculo desse parâmetro foi feito a partir da proporção de área ocupada por cada classe de uso e cobertura da terra em relação ao total. Os valores obtidos podem ser visualizados na Tabela 11.

Tabela 11 - *Neighborhood Weights* (2003 - 2022).

		Área (m²)	Proporção
1	Área Urbana	172.880.376	0,03
2	Vegetação Natural	1.210.444.502	0,22
3	Corpo d'água continental	105.371.528	0,02
4	Área descoberta	2.950.237.112	0,53
5	Agricultura	1.102.967.977	0,20
	Total	5.541.901.495	

Fonte: elaborado pelo autor

Por fim, houve a elaboração da Matriz de Transição, que é fundamental para o entendimento das mudanças existentes na área de estudo. É o momento em que o pesquisador pode inserir no *software* o seu conhecimento prévio sobre o local em análise (Quadro 7).

Quadro 7- Matriz de Transição das classes de uso e cobertura da terra.

	Área Urbana	Vegetação Natural	Corpo d'água continental	Área descoberta	Agricultura
Área urbana	1	0	0	0	0
Vegetação Natural	1	1	0	1	1
Corpo d'água continental	0	1	1	1	0
Área descoberta	1	1	1	1	1
Agricultura	0	0	0	0	1

Fonte: elaborado pelo autor.

As linhas da Matriz de Transição representam as classes de uso e cobertura da terra originais e as colunas estão associadas aos futuros usos e cobertura da terra. No caso da presente pesquisa, foram adotadas as seguintes regras de transição:

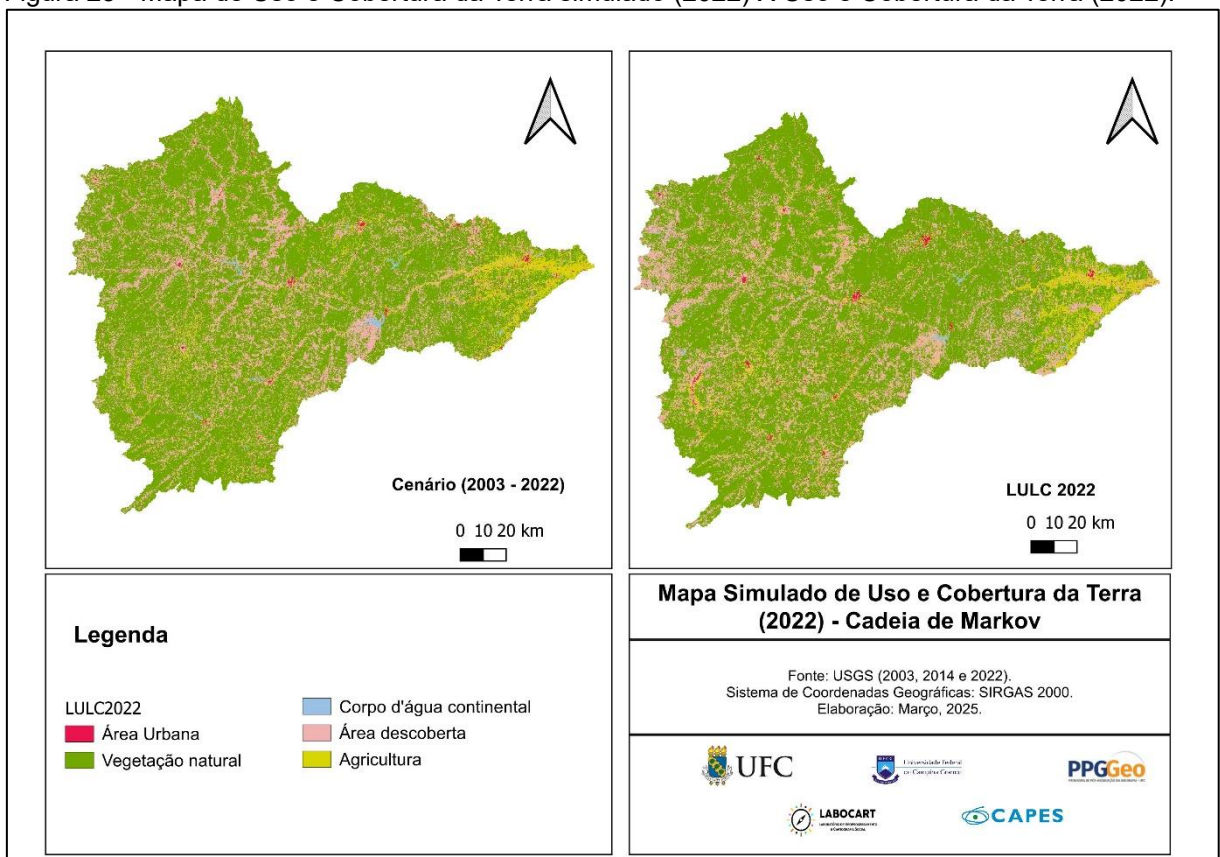
- área urbana: não deve transicionar para outra classe;
- vegetação natural: pode ser alterada para todas as classes com exceção dos corpos d'água continentais;
- corpo d'água continental: não pode transicionar para a área urbana e para a agricultura;
- área descoberta: pode transicionar para todas as outras classes;
- agricultura: não deve transicionar para outra classe.

A Matriz de Transição foi usada em ambos os cenários estudados. O CARS simulou o mapa de uso e cobertura da terra para 2022.

5.3.5 Validação dos resultados (Validation)

A Figura 23 anexada logo abaixo mostra o comparativo visual entre os mapas de Uso e Cobertura da Terra simulados para o ano de 2022 e o dado *raster* produzido para o ano de 2022 elaborado com o método da classificação de imagens supervisionada, utilizado como verdade terrestre para o modelo computacional.

Figura 23 - Mapa de Uso e Cobertura da Terra simulado (2022) X Uso e Cobertura da Terra (2022).



Fonte: elaborado pelo autor.

A Tabela 12 apresenta o comparativo entre a simulação gerada com o cenário de 2003 e 2022 e o dado utilizado como verdade terrestre para o ano de 2022.

Tabela 12 - Diferença entre os cenários simulados e o dado real observado.

Classes	Cenário (2003-2022)	2022	Diferença cenário (2003 -2022)
	Área (km ²)	Área (Km ²)	Área (Km ²)
Área Urbana	217,02	217,07	-0,05
Vegetação natural	13.686,02	13.635,24	50,78
Corpo d'água continental	132,07	165,92	-33,84
Área descoberta	4.260,45	4.254,75	5,71
Agricultura	1.330,32	1.328,56	1,76

Fonte: elaborado pelo autor.

A Figura 23 e a Tabela 12 demonstram que o cenário simulado para o ano de 2022 como dado inicial foi próximo a verdade terrestre de 2022 no comparativo de áreas. As categorias mais discrepantes foram a Vegetação Natural, totalizando 50,78 km² a mais do que o dado observado, e o Corpo d'água continental que registrou 33,84 km² a menos na simulação.

Por último, o mapa produzido foi avaliado com base em algumas métricas utilizadas comumente no sensoriamento remoto como o Coeficiente de Kappa e as Acurácias Globais, de Produção e do Usuário. A literatura indica (Pandey, Kumari e Nawajish, 2023) que para que o ajuste entre o dado simulado e o observado considerado como verdade terrestre seja considerado aceitável o valor calculado para o Coeficiente de *Kappa* e a Acurácia Global deve estar acima de 0,8. Os valores calculados para as métricas de avaliação podem ser visualizados na Tabela 13.

Tabela 13 - Métricas de avaliação para o cenário 2003-2022.
(2003-2022)

Coeficiente de <i>Kappa</i>	0,31
Acurácia Global	0,68
Acurácia de Produção	0,13
Acurácia de Usuário	0,29

Fonte: elaborado pelo autor.

Observa-se, com base na Tabela 13, que o cenário não atingiu o ideal sugerido pela bibliografia científica. O coeficiente Kappa e a Acurácia Global obtidos foi equivalente a 0,31 e 0,68 e, segundo Pandey, Kumari e Nawajish (2023), esses valores estão enquadrados na categoria de um acordo justo abaixo do que seria considerado um ajuste moderado.

As hipóteses para o não alcance dos resultados desejados passam pela

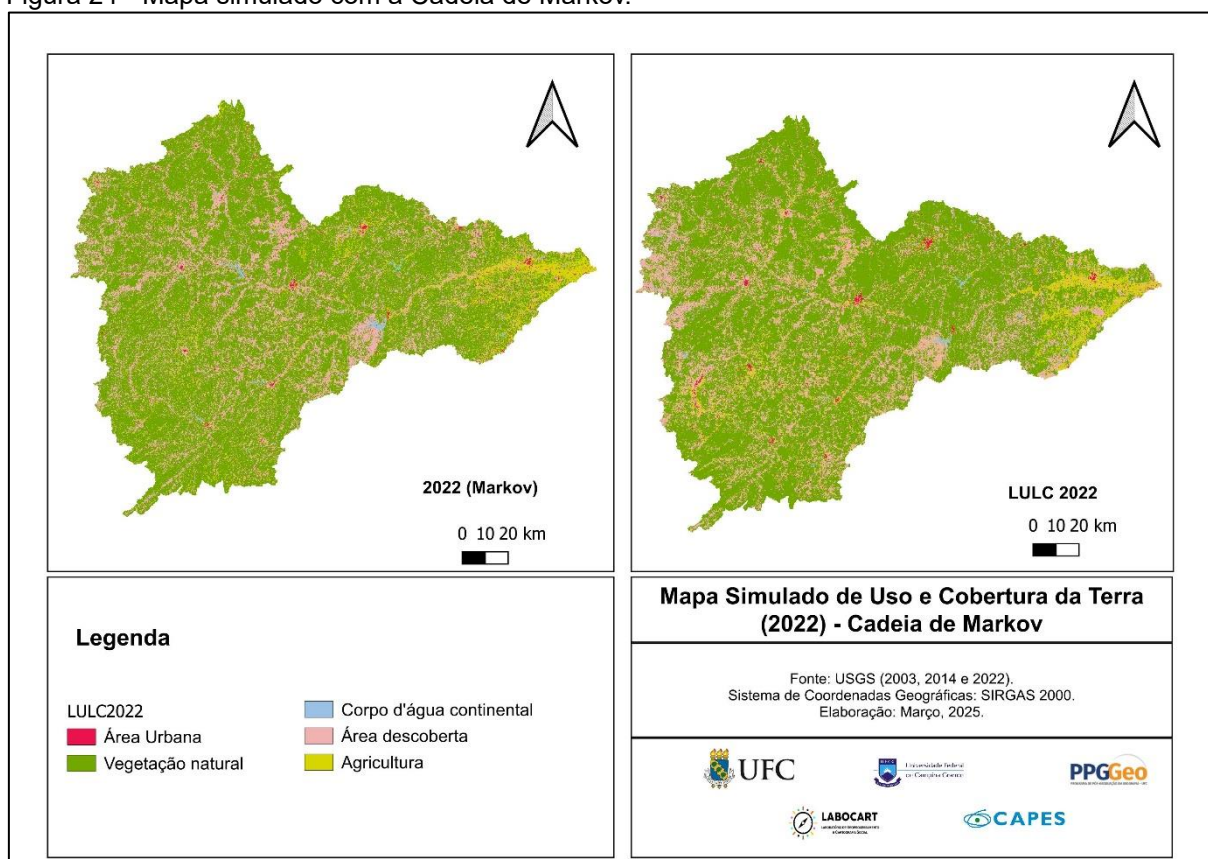
escolha do período analisado, pelas peculiaridades do bioma da Caatinga e pelos fenômenos climáticos presentes na sub-bacia hidrográfica do rio Banabuiú. A principal dificuldade do Sensoriamento Remoto na Caatinga se concentra na dificuldade do mapeamento da cobertura vegetal devido a sazonalidade desse aspecto em relação a precipitação.

Considerando que o ano de 2014 foi um ano atípico para a região pois foi um ano em que predominou uma escassez hídrica provocada pelo fenômeno climático El niño, optou-se nesse estudo pela modelagem baseada no ano de 2003. Nas imagens de satélite adquiridas no ano de 2014, grande parte da vegetação aparece em uma tonalidade mais clara que se confunde com as áreas descobertas, o que colaborou para uma supressão na cobertura vegetal que não foi observada in loco. Esse fato é comprovado pelo aumento no total ocupado pela vegetação nativa observado nas imagens do ano de 2022. O ano de 2003 foi considerado mais capaz de simular o cenário futuro observado por não ter sido afetado gravemente pela escassez hídrica e ser um ano mais típico. Contudo, a semelhança no quantitativo de áreas no cenário 2003-2022 em relação ao dado observado não foi suficiente para uma métrica aceitável no coeficiente de kappa, sendo considerado por isso não aceitável para uma simulação de cenários futuros.

5.3.6 Demand Prediction

Nessa etapa, o cenário de uso e cobertura da terra para o ano de 2022 foi simulado com o método preditivo da Cadeia de Markov associado aos Autômatos Celulares com base nos parâmetros obtidos na etapa referente aos CARS (Figura 24).

Figura 24 - Mapa simulado com a Cadeia de Markov.



Fonte: elaborado pelo autor.

O mapa predito com a Cadeia de Markov é muito semelhante ao dado orbital de uso e cobertura da terra para o ano de 2022. Em termos quantitativos, as áreas superficiais ocupadas por cada categoria foram próximas, conforme demonstra a Tabela 14.

Tabela 14 - Comparação entre o modelo produzido pelo método CARS e a Cadeia de Markov.

Classes	2022 (CARS)	2022	2022 (Cadeia de Markov)
	Área (km ²)	Área (Km ²)	Área (Km ²)
Área Urbana	217,02	217,07	216,86
Vegetação natural	13.686,02	13.635,24	13.689,99
Corpo d'água continental	132,07	165,92	132,20
Área descoberta	4.260,45	4.254,75	4.257,53
Agricultura	1.330,32	1.328,56	1.329,30

Fonte: elaborado pelo autor.

O dado simulado com o método CARS foi o que mais se aproximou do produto apresentado como verdade terrestre. O mapa predito com a Cadeia de

Markov se aproximou bastante do cenário simulado com o método CARS, tendo inclusive apresentado as mesmas métricas de avaliação.

Os resultados obtidos nessa pesquisa contrastam com pesquisas recentes executadas em outros biomas, como as desenvolvidas por Cunha *et al.* (2021) e Lu *et al.* (2019). Cunha *et al.* (2021) obtiveram um ajuste substancial com Índices Kappa acima de 0,7 e 53,22% das mudanças registradas na simulação alocadas corretamente no ecótono Cerrado/Mata Atlântica. O modelo preditivo executado pelos autores Lu *et al.* (2019) na província de Antul, na China, identificaram um aumento em área construída de 200,46% entre 1987 e 2032. Os autores obtiveram Índices Kappa acima de 0,8 e acurácias globais superiores a 92%. Na Caatinga, Fernandes *et al.* (2020) conseguiram avaliar as mudanças no uso e cobertura da terra e as variações no estoque de carbono da floresta nativa com um modelo de autômatos celulares provendo informações cruciais para construção de políticas públicas.

Esses estudos mostram que, apesar de não ter apresentado resultados no monitoramento da cobertura vegetal na sub-bacia do rio Banabuiú, a Cadeia de Markov é um método preditivo de comprovada eficiência em outros biomas. Além disso, esse estudo também abre o leque de possibilidade para o teste de outros modelos preditivos que possam, futuramente, adequar-se melhor às peculiaridades do semiárido nordestino brasileiro.

5.4 Considerações finais

Nota-se que modelagem apresentada nessa pesquisa não teve resultados considerados suficientes para a simulação de cenários futuros de uso e cobertura da terra. Ao olhar para o quantitativo de área ocupada por cada categoria de uso e cobertura da terra, percebe-se que a simulação obtida pelo método CARS e o cenário predito pela Cadeia de Markov se assemelharam bastante, sendo a imagem resultante do método CARS o que mais se aproximou da verdade terrestre.

As métricas de avaliação de ajuste do modelo desenvolvido, Índice Kappa e Acurácia Global, não apresentaram valores suficientes para simulação de cenários futuros de uso e cobertura da terra, fato que pode ser justificado pelas especificidades do bioma Caatinga observadas nos dados orbitais.

O coeficiente Kappa apresentou um valor equivalente a 0,31 e uma Acurácia Global semelhante a 0,68. Segundo Pandey, Kumari e Nawajish (2023), esse

é um ajuste considerado moderado. A evolução temporal nas categorias de uso e cobertura da terra observada nessa pesquisa corrobora com a publicação feita por Tritsch *et al.* (2023) sobre as mudanças ocorridas na sub-bacia hidrográfica do rio Banabuiú.

Apesar da modelagem da cobertura do uso e cobertura da terra não ter apresentado resultados suficientes para ter confiabilidade em termos de previsibilidade, essa pesquisa atenta para a necessidade de monitoramento da vegetação nativa do bioma Caatinga. Sugere-se como trabalhos futuros o uso de modelos baseados em séries temporais anuais a fim de captar maiores nuances ao longo dos anos.

6 CONSIDERAÇÕES FINAIS

Em tempos em que as ferramentas de inteligência artificial estão cada vez mais popularizadas, com uso na pesquisa acadêmica e em órgãos governamentais, auxiliando, por exemplo, no combate ao desmatamento, é necessário checar e validar as informações produzidas por esse tipo de algoritmo.

No ramo do sensoriamento remoto, alguns modelos matemáticos e de aprendizagem de máquina foram validados com sucesso em diversas regiões, em virtude das características de inovação e automação que podem ser agregadas nessa área de conhecimento (Permatasari *et al.*, 2021; Maurya; Rafi; Shamoo, 2023; Floreano; Moraes, 2021; Santos *et al.*, 2024; Lary *et al.*, 2016; Zhang *et al.*, 2023; Akdeniz; Sag; Inam, 2023). A ferramenta utilizada como teste nessa pesquisa foi o modelo híbrido CA-Markov que é uma junção entre os Autômatos Celulares e a Cadeia de Markov (CA-Markov) e já foi aplicada com eficácia em outros biomas brasileiros (Santos *et al.*, 2024; Cunha *et al.*, 2021; Floreano; Moraes, 2021; Cunha *et al.*, 2022). Na Caatinga, não foram encontrados até então exemplos do uso do modelo CA-Markov no auxílio ao monitoramento da cobertura da cobertura vegetal, fato que motivou o desenvolvimento dessa pesquisa.

Essa ausência de publicações na Caatinga pode ser explicada pelas dificuldades e limitações do sensoriamento remoto na caracterização da cobertura foliar presente nesse Bioma. Como explicado e exemplificado pela análise nos capítulos anteriores, a vegetação predominante na Caatinga é do tipo caducifólia, ou seja, que perde as folhas em épocas mais secas como forma de adaptação à escassez hídrica. Nas imagens de plataformas orbitais, como as registradas pela série de satélites do Landsat, o alvo da vegetação se assemelha mais com a aparência de uma floresta densa e, em meses com baixa pluviosidade, aproxima-se mais do comportamento espectral de uma área descoberta. É o caso da sub-bacia hidrográfica do rio Banabuiú, escolhida para a execução dessa pesquisa, uma área situada no sertão central do estado do Ceará em uma região totalmente inserida no semiárido, com uma área superficial semelhante a 19.603,094 km² e abrangendo 15 municípios.

Nesse trabalho, o capítulo 2 envolveu uma revisão bibliográfica e bibliométrica sobre modelos preditivos no âmbito do sensoriamento remoto em estudos de uso e cobertura da terra, demonstrando a incipiência de estudos sobre o modelo híbrido CA-Markov no Brasil. A caracterização ambiental da sub-bacia

hidrográfica do rio Banabuiú é apresentada no capítulo 3, que foi importante para o entendimento dos aspectos físicos e socioeconômicos presentes na área estudada.

O capítulo 4, com a análise temporal de uso e cobertura da terra, indicou uma tendência de supressão e recomposição da cobertura vegetal durante o período estudado na referida área. Com relação aos corpos hídricos e às áreas ocupadas pela agropecuária, o estudo corroborou a publicação feita por Tritsch *et al.* (2023) com a comprovação da construção de pequenos açudes próximos às áreas de pecuária leiteira entre os anos de 2014 a 2022.

No capítulo 5, foi descrita a modelagem em si do uso e cobertura da terra na área estudada e foi executado o modelo de simulação das alterações de uso e cobertura de terra baseado nos anos de 2003 e 2022. O ano de 2022 foi predito com base no modelo CA-Markov para fins de validação do ajuste da modelagem. Os resultados obtidos não foram considerados suficientes para a predição de cenários futuros de uso e cobertura da terra.

Essa pesquisa expõe as limitações técnicas da modelagem preditiva de uso e cobertura da terra em ambientes como o bioma da Caatinga, presente na sub-bacia hidrográfica do rio Banabuiú. O aspecto caducifólio da vegetação da Caatinga foi o principal fator de dificuldade para a modelagem para a classe referente à cobertura vegetal, uma vez que essa característica produz falsos alarmes com relação ao desmatamento. A predominância da agricultura familiar também um é fator negativo para a modelagem devido ao tamanho das parcelas não se destacar muito em comparação a outras categorias. Como já comentado, essa pesquisa atenta para a necessidade de monitoramento da vegetação nativa do bioma Caatinga. Entende-se que sensoriamento remoto pode contribuir com essa vigilância com o intuito de prover um desenvolvimento sustentável na região, desde que seja acompanhado de supervisões *in loco*. O uso de imagens com resoluções espaciais que permitam a visualização de um maior nível de detalhe do terreno e, consequentemente, computadores com maiores capacidades de processamento são medidas que também podem ser adotadas para uma maior precisão da modelagem preditiva e que, assim, viabilizariam mais pesquisas futuras sobre a região.

REFERÊNCIAS

- ABIJITH, Devanantham; SARAVANAN, Subbarayan. Assessment of land use and land cover change detection and prediction using remote sensing and CA Markov in the northern coastal districts of Tamil Nadu, India. **Environmental Science and Pollution Research**, [S.l.], v. 29, n. 57, p. 86055–86067, 2022. Disponível em : <https://link.springer.com/article/10.1007/s11356-021-15782-6>. Acesso em: 19 nov. 2023.
- ABURAS, Maher Milad; AHAMAD, Mohd Sanusi S.; OMAR, Najat Qader. Spatio-temporal simulation and prediction of land-use change using conventional and machine learning models: a review. **Environmental Monitoring and Assessment**, [S.l.], v. 191, n. 4, 2019. Disponível em : <https://link.springer.com/article/10.1007/s10661-019-7330-6>. Acesso em: 19 nov. 2023.
- AGEITEC. **Abertura**. Brasília, DF: Embrapa, 2022. Disponível em: <https://www.embrapa.br/agencia-de-informacao-tecnologica/tematicas/bioma-caatinga>. Acesso em: 20 nov. 2024.
- AGUSTINA, Ina Helena; AJI, Riswandha Risang; FARDANI, Irland; ROCHMAN, Gina Puspitasari; EKASARI, Astri Mutia; MOHMED, Fhanji Alain Jauzi. Cellular Automata for Cirebon City Land Cover and Development Prediction. **Planning Malaysia**, [S.l.], v. 20, n. 1, p. 77-88, 18 abr. 2022. Malaysian Institute of Planners. <http://dx.doi.org/10.21837/pm.v20i20.1080>. Disponível em: <https://www.planningmalaysia.org/index.php/pmj/article/view/1080>. Acesso em: 20 nov. 2023.
- AKDENIZ, Halil Burak; SAG, Neslihan Serdaroglu; INAM, Saban. Analysis of land use/land cover changes and prediction of future changes with land change modeler: Case of Belek, Turkey. **Environmental Monitoring and Assessment**, [S.l.], v. 195, n. 1, 2023. Springer International Publishing. Disponível em: <https://doi.org/10.1007/s10661-022-10746-w>. Acesso em: 19 nov. 2024.
- ALQADHI, Saeed; MALLICK, Javed; BALHA, Akanksha; BINDAJAM, Ahmed; SINGH, Chander Kumar; HOA, Pham Viet. Spatial and decadal prediction of land use/land cover using multi-layer perceptron-neural network (MLP-NN) algorithm for a semi-arid region of Asir, Saudi Arabia. **Earth Science Informatics**, [S.l.], v. 14, n. 3, p. 1547-1562, 24 jun. 2021. Disponível em: <http://dx.doi.org/10.1007/s12145-021-00633-2>. Acesso em: 09 nov. 2024.
- ANIAH, Philip; BAWAKYILLENUO, Simon; CODJOE, Samuel Nii Ardey; DZANKU, Fred Mawunyo. Land use and land cover change detection and prediction based on CA-Markov chain in the savannah ecological zone of Ghana. **Environmental Challenges**, v. 10, n. November 2022, p. 100664, 2023. Elsevier B.V. Disponível em: <https://doi.org/10.1016/j.envc.2022.100664>. Acesso em: 20 nov. 2023.
- ANSARI, Amir; GOLABI, Mohammad H. Prediction of spatial land use changes based on LCM in a GIS environment for Desert Wetlands – A case study: Meighan Wetland, Iran. **International Soil and Water Conservation Research**, [S.l.], v. 7, n.

1, p. 64–70, 2019. Disponível em: <http://dx.doi.org/10.1016/j.iswcr.2018.10.001>. Acesso em: 19 nov. 2024.

ARANHA, Thaís R. Benevides T.; MARTINEZ, Jean-Michel; SOUZA, Enio P.; BARROS, Mário U. G.; MARTINS, Eduardo Sávio P. R.. Remote Analysis of the Chlorophyll-a Concentration Using Sentinel-2 MSI Images in a Semiarid Environment in Northeastern Brazil. **Water**, [S.l.], v. 14, n. 3, p. 451, 2 fev. 2022. Disponível em: <http://dx.doi.org/10.3390/w14030451>. Acesso em: 09 nov. 2024.

ARAÚJO, Matheus Duarte de; RIBEIRO, Márcia Maria Rios; BRAGA, Cybelle Frazão Costa. Integrando a modelagem da alocação de água ao sistema de indicadores FPEIR: aplicação ao semiárido do Brasil. **Engenharia Sanitária e Ambiental**, [S.l.], v. 24, n. 6, p. 1167-1181, dez. 2019. Disponível em: <http://dx.doi.org/10.1590/s1413-41522019184425>. Acesso em: 09 nov. 2024.

ARNOUS, Mohamed O.; EL-RAYES, Ahmed E.; HELMY, Ahmed M.. Land-use/land-cover change: a key to understanding land degradation and relating environmental impacts in northwestern Sinai, Egypt. **Environmental Earth Sciences**, [S.l.], v. 76, n. 7, p. 1-21, 29 mar. 2017. Disponível em: <http://dx.doi.org/10.1007/s12665-017-6571-3>. Acesso em: 09 nov. 2024.

ASATY, Thomas L. **The Analytic Hierarchy Process: planning, priority setting, resource allocation**. New York: McGraw-Hill, 1980.

AVTAR, Ram; RINAMALO, Apisai Vakacegu; UMARHADI, Deha Agus; GUPTA, Ankita; KHEDHER, Khaled Mohamed; YUNUS, Ali P.; SINGH, Bhupendra P.; KUMAR, Pankaj; SAHU, Netrananda; SAKTI, Anjar Dimara. Land Use Change and Prediction for Valuating Carbon Sequestration in Viti Levu Island, Fiji. **Land**, [S.l.], v. 11, n. 8, p. 1-17, 8 ago. 2022. Disponível em: <https://www.mdpi.com/2073-445X/11/8/1274>. Acesso em: 09 nov. 2023.

BACANI, Vitor Matheus; SILVA, Bruno Henrique Machado da; SATO, Ayumi de Souza Amede; SAMPAIO, Bruna Dienifer Souza; CUNHA, Elias Rodrigues da; VICK, Erivelton Pereira; OLIVEIRA, Víncler Fernandes Ribeiro de; DECCO, Hermiliano Felipe. Carbon storage and sequestration in a eucalyptus productive zone in the Brazilian Cerrado, using the Ca-Markov/Random Forest and InVEST models. **Journal of Cleaner Production**, [S.l.], v. 444, p. 141291, 2024. Disponível em: <https://doi.org/10.1016/j.jclepro.2024.141291>. Acesso em: 09 nov. 2023.

BAKR, Noura; MORSY, I.; YEHIA, H. A. Spatio-temporal land use/cover detection and prediction in Mediterranean region: A case study in Idku ecosystem, Egypt. **Remote Sensing Applications: Society and Environment**, [S.l.], v. 25, p. 100673, 2022. Disponível em: <https://doi.org/10.1016/j.rsase.2021.100673>. Acesso em: 09 nov. 2023.

BARNESLEY, Michael John. **Environmental modeling: a practical introduction**. Boca Raton, US: CRC Press, 2007.

BELGIU, Mariana; DRĂGŪN, Lucian. Random forest in remote sensing: a review of applications and future directions. **Isprs Journal Of Photogrammetry And Remote**

Sensing, [S./], v. 114, p. 24-31, abr. 2016. Elsevier BV.
<http://dx.doi.org/10.1016/j.isprsjprs.2016.01.011>. Disponível em:
<https://www.sciencedirect.com/science/article/abs/pii/S0924271616000265>. Acesso em: 09 nov. 2022.

BESHIR, Siraj; MOGES, Awdenegest; DANANTO, Mihret. Trend analysis, past dynamics and future prediction of land use and land cover change in upper Wabe-Shebele river basin. **Heliyon**, v. 9, n. 9, p. e19128, 2023. Ltd. Disponível em: <https://doi.org/10.1016/j.heliyon.2023.e19128>. Acesso em: 19 nov. 2024.

BHARGAVA, Deepshikha; POONIA, Ramesh C.; Arora, UPMA. Design and development of an intelligent agent based framework for predictive analytics. *In*: International Conference on Computing for Sustainable Global Development, 3, New Delhi. **Anais** [...], New Delhi: INDIACom, 2016, p. 3715-3718. Disponível em: <https://ieeexplore.ieee.org/document/7724956/citations?tabFilter=papers#citations>. Acesso em: 09 nov. 2024.

BIECEK, Przemyslaw. Dalex: Explainers for complex predictive models in R. **Journal of Machine Learning Research**, [S./], v. 19, p. 1–5, 2018. Disponível em: <https://jmlr.org/papers/v19/18-416.html>. Acesso em: 09 nov. 2022.

BIELSKI, Conrad; LÓPEZ-VÁZQUEZ, Carlos; GROHMANN, Carlos H.; GUTH, Peter L.; HAWKER, Laurence; GESCH, Dean; TREVISANI, Sebastiano; HERRERA-CRUZ, Virginia; RIAZANOFF, Serge; CORSEAU, Axel. Novel Approach for Ranking DEMs: copernicus dem improves one arc second open global topography. **Ieee Transactions On Geoscience And Remote Sensing**, [S./], v. 62, n. 1, p. 1-22, 2024. Disponível em: <http://dx.doi.org/10.1109/tgrs.2024.3368015>. Acesso em: 09 nov. 2024.

BRANDÃO, Ricardo de Lima; FREITAS, Luis Carlos Bastos (org.). **Geodiversidade do estado do Ceará**. Fortaleza: CPRM, 2014. Disponível em: <https://rigeo.sgb.gov.br/handle/doc/16726>. Acesso em: 09 nov. 2024.

BRASIL. **Lei nº 6938, de 31 de agosto de 1981**. Dispõe sobre a Política Nacional do Meio Ambiente, seus fins e mecanismos de formulação e aplicação, e dá outras providências. Brasília – DF: Presidência da República, 1981. Disponível em: https://www.planalto.gov.br/ccivil_03/leis/l6938.htm. Acesso em: 19 fev. 2024.

BREIMAN, Leo. Random Forests. **Machine Learning**, [S./], v. 45, n. 1, p. 5-32, out. 2001. Disponível em: <http://dx.doi.org/10.1023/a:1010933404324>. Acesso em: 09 nov. 2024.

BRITO, Pedro Vinícius da Silva; SANTOS, Tayran Oliveira dos; MORAIS, Ygor Cristiano Brito. Análise da sazonalidade da vegetação de caatinga do município de Petrolina (Pernambuco) a partir de imagens do satélite Landsat-8 OLI. **Revista Brasileira de Sensoriamento Remoto**, v. 1, n. 1, p. 29–37, 2020. Disponível em: <https://rbsr.com.br/index.php/RBSR/article/view/6/5>. Acesso em: 09 nov. 2024.

CEARÁ. Assembleia Legislativa do Estado do Ceará (org.). **Caderno regional da sub-bacia do Banabuiú**. Fortaleza: INESP, 2009. 2. v. Disponível em:

<https://portal.cogerh.com.br/wp-content/uploads/2018/09/Bacia-do-Banabui%C3%BA.pdf>. Acesso em: 10 jan. 2025.

CEARÁ. **Histórico**. Fortaleza: Secretaria de Recursos Hídricos, c2017. Disponível em: <https://www.srh.ce.gov.br/historico/>. Acesso em: 10 jan. 2025.

CEARÁ. **Inventário Ambiental do Açude Banabuiú**. Fortaleza, Ceará, 2011. Disponível em: <https://portal.cogerh.com.br/wp-content/uploads/pdf/inventarios/2011/Inventario%20Ambiental%20do%20Acude%20Banabui%202011.pdf>. Acesso em: 09 nov. 2024.

CHANG, Yue; HOU, Kang; LI, Xuxiang; ZHANG, Yunwei; CHEN, Pei. Review of Land Use and Land Cover Change research progress. **Iop Conference Series: Earth and Environmental Science**, [S.l.], v. 113, p. 012087, fev. 2018. Disponível em: <http://dx.doi.org/10.1088/1755-1315/113/1/012087>. Acesso em: 09 nov. 2024.

CHIM, Kosal; TUNNICLIFFE, Jon; SHAMSELDIN, Asaad; OTA, Tetsuji. Land Use Change Detection and Prediction in Upper Siem Reap River, Cambodia. **Hydrology**, [S.l.], v. 6, n. 3, p. 64, 25 jul. 2019. Disponível em: <http://dx.doi.org/10.3390/hydrology6030064>. Acesso em: 09 nov. 2024.

CHRISTOFOLETTI, Antonio. **Geomorfologia**. 2ª ed. São Paulo: Edgard Blucher, 1980.

CIOLPAN, Gheorghe. Autómatos celulares. In: RAMOS, Carlos; BANDEIRA, Luís (ed.). **Tópicos de análise**. Universidade de Évora: Évora, 2022. Disponível em: chrome-extension://efaidnbmnnnibpcajpcglclefindmkaj/https://dspace.uevora.pt/rdpc/bitstream/10174/32601/1/Topicos_analise_book_final_2022.pdf. Acesso em: 09 nov. 2024.

CONACHER, Arthur J. ; SALA, Maria (ed.). **Land degradation in Mediterranean environments of the world**. Wiley : Chichester, 1998.

COSTA, Luis Ricardo Fernandes da; OLIVEIRA, Vlória Pinto Vidal de; SANTOS, Jader de Oliveira. Contexto Geoambiental em Sítio Urbano na Sub-bacia Hidrográfica do rio Banabuiú - CE Environmental Context in Urban Sites in the Banabuiú River water basin – CE. **Revista Verde Geografia e Interdisciplinaridade**. v. 01, p. 23-33, 2019. Disponível em: <https://doi.org/10.46551/rvg26752395201912333>. Acesso em: 09 nov. 2024.

CUNHA, Elias Rodrigues da; SANTOS, Celso Augusto Guimarães; SILVA, Richarde Marques da; PANACHUKI, Elói; OLIVEIRA, Paulo Tarso Sanches de; OLIVEIRA, Naelmo de Souza; FALCÃO, Karina dos Santos. Assessment of current and future land use/cover changes in soil erosion in the Rio da Prata basin (Brazil). **Science Of The Total Environment**, [S.l.], v. 818, p. 151811, abr. 2022. Disponível em: <http://dx.doi.org/10.1016/j.scitotenv.2021.151811>. Acesso em: 09 nov. 2024.

CUNHA, Elias Rodrigues da; SANTOS, Celso Augusto Guimarães; SILVA, Richarde Marques da; BACANI, Vitor Matheus; POTT, Arnildo. Future scenarios based on a CA-Markov land use and land cover simulation model for a tropical humid basin in

the Cerrado/Atlantic forest ecotone of Brazil. **Land Use Policy**, [S.l.], v. 101, n. 1, p. 105141-105141, fev. 2021. Elsevier BV.

<http://dx.doi.org/10.1016/j.landusepol.2020.105141>. Disponível em:

<https://www.sciencedirect.com/science/article/abs/pii/S0264837720303288>. Acesso em: 18 nov. 2024.

DERRY, Alexander; KRZYWINSKI, Martin; ALTMAN, Naomi. Neural networks primer. **Nature Methods**, [S.l.], v. 20, n. 2, p. 165-167, 10 jan. 2023. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41592-022-01747-1>. Disponível em: <https://www.nature.com/articles/s41592-022-01747-1#citeas>. Acesso em: 20 nov. 2024.

DNOCS. **Perímetro Irrigado de Morada Nova Completa 51 anos**. 2021. Disponível em: <https://www.gov.br/dnocs/pt-br/assuntos/noticias/perimetro-irrigado-de-morada-nova-completa-51-anos>. Acesso em: 01 set. 2023.

DRUCK, Suzana; CARVALHO, Marília Sá; CÂMARA, Gilberto; MONTEIRO, Antônio Miguel Vieira. *Análise Espacial de Dados Geográficos*. Brasília, EMBRAPA, 2004 (ISBN: 85-7383-260-6).

EMBRAPA. **Serviço Nacional de Levantamento e Conservação de Solos**. Súmula da 10. Reunião Técnica de Levantamento de Solos. Rio de Janeiro: Embrapa, 1979. 83p. (EMBRAPA-SNLCS. Micelânea, 1). Disponível em: <https://www.infoteca.cnptia.embrapa.br/infoteca/handle/doc/327212>. Acesso em: 09 nov. 2024.

FEITOSA, Thaiana Brunes; FERNANDES, Milton Marques; SANTOS, Celso Augusto Guimarães; SILVA, Richarde Marques da; GARCIA, Junior Ruiz; ARAUJO FILHO, Renisson Neponuceno de; FERNANDES, Márcia Rodrigues de Moura; CUNHA, Elias Rodrigues da. Assessing economic and ecological impacts of carbon stock and land use changes in Brazil's Amazon Forest: a 2050 projection. **Sustainable Production And Consumption**, [S.l.], v. 41, p. 64-74, out. 2023. Elsevier BV. <http://dx.doi.org/10.1016/j.spc.2023.07.009>. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S2352550923001641>. Acesso em: 18 nov. 2024.

FERNANDES, Milton Marques; FERNANDES, Márcia Rodrigues de Moura; GARCIA, Junior Ruiz; MATRICARDI, Eraldo Aparecido Trondoli; ALMEIDA, André Quintão de; PINTO, Alexandre Siqueira; MENEZES, Rômulo Simões Cezar; SILVA, Ademilson de Jesus; LIMA, Alexandre Herculano de Souza. Assessment of land use and land cover changes and valuation of carbon stocks in the Sergipe semiarid region, Brazil: 1992–2030. **Land Use Policy**, v. 99, p. 104795, 2020. Elsevier. Disponível em: <https://doi.org/10.1016/j.landusepol.2020.104795>.

FLECK, Leandro; TAVARES, Maria Hermínia Ferreira; EYNG, Eduardo; HELMANN, Andrieli Cristina; ANDRADE, Minéia Aparecida de Moares. Redes neurais artificiais: princípios básicos. **Revista Eletrônica Científica Inovação e Tecnologia**, [S.l.], v. 7, n. 15, p. 47, 31 mar. 2016. Disponível em: <http://dx.doi.org/10.3895/recit.v7.n15.4330>. Acesso em: 09 nov. 2024.

FLOREANO, Isabela Xavier; MORAES, Luzia Alice Ferreira de. Land use/land cover (LULC) analysis (2009–2019) with Google Earth Engine and 2030 prediction using Markov-CA in the Rondônia State, Brazil. **Environmental Monitoring And Assessment**, [S.l.], v. 193, n. 4, p. 1-17, 2021. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10661-021-09016-y>. Disponível em: <https://doi.org/10.1002/srin.202200388>. Acesso em: 09 nov. 2024.

FONSECA, Fernando Pereira da; RAMOS, Rui António Rodrigues; SILVA, António Nelson Rodrigues da. Um Modelo Baseado em Agentes para Simular Políticas de Ordenamento de Áreas de Acolhimento. **Rper**, [S.l.], n. 41, p. 5-20, 31 mar. 2016. Associação Portuguesa para o Desenvolvimento Regional. Disponível em: <https://www.review-rper.com/index.php/rper/article/view/371>. Acesso em: 09 nov. 2024.

Forrester, Jay Wright. **Industrial dynamics**. Waltham, MA : Pegasus Communications, 1961.

FREITAS, Eliana Vieira de; ARAKI, Hideo. SIMULATION OF URBAN GROWTH: a case study for Curitiba city, Brazil. **Boletim de Ciências Geodésicas**, [S.l.], v. 27, n. , e2021019, 2021. Disponível em: <http://dx.doi.org/10.1590/s1982-21702021000s00019>. Acesso em: 09 nov. 2024.

FUCK JÚNIOR, Sérgio César de França. SUBSÍDIO À GESTÃO AMBIENTAL: DESCRIÇÃO FISIAGRÁFICA E ANÁLISE FUNCIONAL DAS BACIAS HIDROGRÁFICAS DO CEARÁ. **Geoambiente On-line**, Goiânia, n. 10, p. 01–31 pág., 2008. Disponível em: <https://revistas.ufj.edu.br/geoambiente/article/view/25953>. Acesso em: 25 jul. 2024.

FUNCEME. **Portal Hidrológico do Ceará**. Fortaleza: Funceme, c2024. Disponível em: <http://www.hidro.ce.gov.br/>. Acesso em: 02 jan. 2022.

FUNCEME. **Índices de Aridez do Estado do Ceará**. [2023]. Disponível em: http://www.funceme.br/?page_id=5826. Acesso em: 15 set. 2023.

GAO, Yuan; WANG, Jinman; ZHANG, Min; LI, Sijia. Measurement and prediction of land use conflict in an opencast mining area. **Resources Policy**, [S.l.], v. 71, p. 101999, jun. 2021. Disponível em: <http://dx.doi.org/10.1016/j.resourpol.2021.101999>. Acesso em: 09 nov. 2024.

HAMAD, Rahel; BALZTER, Heiko; KOLO, Kamal. Predicting Land Use/Land Cover Changes Using a CA-Markov Model under Two Different Scenarios. **Sustainability**, [S.l.], v. 10, n. 10, p. 1-23, 25 set. 2018. Disponível em: <https://doi.org/10.3390/su10103421>. Acesso em: 09 nov. 2024.

HASSAN, Zahra; SHABBIR, Rabia; AHMAD, Sheikh Saeed; MALIK, Amir Haider; AZIZ, Neelam; BUTT, Amna; ERUM, Summra. Dynamics of land use and land cover change (LULCC) using geospatial techniques: a case study of Islamabad Pakistan. **Springerplus**, [S.l.], v. 5, n. 1, p. 812, 21 jun. 2016. Disponível em: <http://dx.doi.org/10.1186/s40064-016-2414-z>. Acesso em: 09 nov. 2024.

HE, Jianhua; HUANG, Junlong; LI, Chun. The evaluation for the impact of land use change on habitat quality: a joint contribution of cellular automata scenario simulation and habitat quality assessment model. **Ecological Modelling**, v. 366, p. 58–67, 2017. Disponível em: <http://dx.doi.org/10.1016/j.ecolmodel.2017.10.001>. Acesso em: 09 nov. 2024.

HOQUE, Muhammad Ziaul; ISLAM, Imranul; AHMED, Minhaz; HASAN, Shaikh Shamim; PRODHAN, Ahmed, Foyez. Spatio-temporal changes of land use land cover and ecosystem service values in coastal Bangladesh. **Egyptian Journal of Remote Sensing and Space Science**, v. 25, n. 1, p. 173–180, 2022. Disponível em: <https://doi.org/10.1016/j.ejrs.2022.01.008>. Acesso em: 09 nov. 2024.

HOU, Jun; QIN, Tianlin; LIU, Shanshan.; *et al.* **Analysis and prediction of ecosystem service values based on land use/cover change in the yiluo river basin**. Sustainability (Switzerland), v. 13, n. 11, p. 1–14, 2021.

IBGE. **Banco de Dados de Informações Ambientais**. Rio de Janeiro: IBGE, c2023. Disponível em: <https://bdiaweb.ibge.gov.br/#/home>. Acesso em: 09 nov. 2024.

IBGE. **IBGE Cidades e estados do Brasil**. Rio de Janeiro: IBGE, c2013.

IBGE. **Manual Técnico de Pedologia**. 3. ed. Rio de Janeiro: IBGE, 2015. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=295017>. Acesso em: 09 nov. 2024.

JÚNIOR, Divaldo Portilho Fernandes; JÚNIOR, Valdivino Vargas. **Conceitos e simulação de Cadeias de Markov**. [S.l.]: Universidade Federal de Goiás, 2011. Disponível em: http://www.sbpnet.org.br/livro/63ra/conpeex/pivic/trabalhos/DIVALDO_.PDF. Acesso em: 09 nov. 2024.

KARIMI, Hazhir; JAFARNEZHAD, Javad; KHALEDI, Jabbar; AHMADI, Parisa. Monitoring and prediction of land use/land cover changes using CA-Markov model: a case study of ravansar county in iran. **Arabian Journal Of Geosciences**, [S.l.], v. 11, n. 19, p. 1-9, out. 2018. Disponível em: <https://link.springer.com/article/10.1007/s12517-018-3940-5>. Acesso em: 09 nov. 2024.

KHAN, Zubair; SAEED, Ahmed; BAZAI, Mohammad Haroon. Land use/land cover change detection and prediction using the CA-Markov model: A case study of Quetta city, Pakistan. **Journal of Geography and Social Sciences (JGSS)**, v. 2, n. 2, p. 164–182, 2020. Disponível em: https://www.researchgate.net/publication/355209516_Land_useland_cover_change_detection_and_prediction_using_the_CA-Markov_model_A_case_study_of_Quetta_city_Pakistan. Acesso em: 09 nov. 2024.

KHAWALDAH, Hamzah Ali.; FARHAN, Ibrahim; ALZBOUN, Nidal. Simulation and prediction of land use and land cover change using GIS, remote sensing and CA-Markov model. **Global Journal Of Environmental Science And Management**, [S.l.], v. 6, n. 2, p. 215-232, abr. 2020. Disponível em:

<http://dx.doi.org/10.22034/gjesm.2020.02.07>. Acesso em: 09 nov. 2024.

KHWARAHM, Nabaz R.; NAJMADDIN, Peshawa M.; ARARAT, Korsh; QADER, Sarchil. Past and future prediction of land cover land use change based on earth observation data by the CA–Markov model: a case study from duhok governorate, iraq. **Arabian Journal Of Geosciences**, [S.l.], v. 14, n. 15, 28 jul. 2021. Disponível em: <https://doi.org/10.1007/s12517-021-07984-6>. Acesso em: 09 nov. 2024.

KULKARNI, Keerti; VIJAYA, Pa. NDBI Based Prediction of Land Use Land Cover Change. **Journal Of The Indian Society Of Remote Sensing**, [S.l.], v. 49, n. 10, p. 2523-2537, 16 jul. 2021. Disponível em: <https://doi.org/10.1007/s12524-021-01411-9>. Acesso em: 09 nov. 2024.

KUMAR, Vaibhav; GARG, L., M.. Predictive Analytics: a review of trends and techniques. **International Journal Of Computer Applications**, [S.l.], v. 182, n. 1, p. 31-37, 16 jul. 2018. Disponível em: <http://dx.doi.org/10.5120/ijca2018917434>. Acesso em: 09 nov. 2024.

KWAKKEL, J. H. J. H.; WALKER, W. E.; MARCHAU, V. A. W. J. From predictive modeling to exploratory modeling: how to use non-predictive models for decisionmaking under deep uncertainty. **Proceedings of the 25th Mini-EURO Conference on Uncertainty and Robustness in Planning and Decision Making (URPDM2010)**, 2015, p. 1–10, 2010. Disponível em: https://www.academia.edu/21016781/From_predictive_modeling_to_exploratory_modeling_How_to_use_non_predictive_models_for_decisionmaking_under_deep_uncertainty. Acesso em: 09 nov. 2024.

LARY, David J.; ALAVI, Amir H.; GANDOMI, Amir H.; WALKER, Annette L.. Machine learning in geosciences and remote sensing. **Geoscience Frontiers**, [S.l.], v. 7, n. 1, p. 3-10, jan. 2016. Disponível em: <http://dx.doi.org/10.1016/j.gsf.2015.07.003>. Acesso em: 09 nov. 2024.

LETA, Megersa Kebede; DEMISSIE, Tamene Adguna; TRÄNCKNER, Jens. Modeling and prediction of land use land cover change dynamics based on land change modeler (Lcm) in nashe watershed, upper blue Nile basin, Ethiopia. **Sustainability**, [S.l.], v. 13, n. 7, p. 3740-3740, 27 mar. 2021. Disponível em: <https://doi.org/10.3390/su13073740>. Acesso em: 09 nov. 2024.

LI, W.; ZHANG, C.. Markov Chain Analysis. **International Encyclopedia Of Human Geography**, [S.l.], p. 455-460, 2009. Disponível em: <http://dx.doi.org/10.1016/b978-008044910-4.00470-3>. Acesso em: 09 nov. 2024.

LIANG, Xun; GUAN, Qingfeng; CLARKE, Keith C.; LIU, Shishi; WANG, Bingyu; YAO, Yao. Understanding the drivers of sustainable land expansion using a patch-generating land use simulation (PLUS) model: a case study in wuhan, china. **Computers, Environment And Urban Systems**, [S.l.], v. 85, p. 101569, jan. 2021. Disponível em: <http://dx.doi.org/10.1016/j.compenvurbsys.2020.101569>. Acesso em: 09 nov. 2024.

LIMA, Maria Maiany Paiva; SILVA, Lucas da. Análise da Vulnerabilidade Natural da Bacia Hidrográfica do Rio Banabuiú, com Apoio de Geotecnologia. **Revista Brasileira de Geografia Física**, [S.l.], v.11, n.04, p. 1442-1457, 2018. Disponível em: <https://periodicos.ufpe.br/revistas/index.php/rbgfe/article/view/234363>. Acesso em: 09 nov. 2024.

LIPING, Chen; YUJUN, Sun; SAEED, Sajjad. Monitoring and predicting land use and land cover changes using remote sensing and GIS techniques—A case study of a hilly area, Jiangle, China. **Plos One**, [S.l.], v. 13, n. 7, p. e0200493, 13 jul. 2018. Disponível em: <http://dx.doi.org/10.1371/journal.pone.0200493>. Acesso em: 09 nov. 2024.

LOPES, Fernando B.; BARBOSA, Cláudio C. F.; NOVO, Evelyn M. L. de M.; ANDRADE, Eunice M. de; CHAVES, Luiz C. G.. Modelagem da qualidade das águas a partir de sensoriamento remoto hiperespectral. **Revista Brasileira de Engenharia Agrícola e Ambiental**, [S.l.], v. 18, n. , p. 13-19, 2014. Disponível em: <http://dx.doi.org/10.1590/1807-1929/agriambi.v18nsupps13-s19>. Acesso em: 09 nov. 2024.

LOTKA, Alfred J. The frequency distribution of scientific productivity. **Journal of the Washington Academy of Sciences**, Washington, v. 16, n. 12, p. 317-323, 1926. Disponível em: <https://www.jstor.org/stable/24529203>. Acesso em 12. ago. 2024.

LU, Yuting; WU, Penghai; MA, Xiaoshuang; LI, Xinghua. Detection and prediction of land use/land cover change using spatiotemporal data fusion and the Cellular Automata–Markov model. **Environmental Monitoring And Assessment**, [S.l.], v. 191, n. 2, 14 jan. 2019. Disponível em: <https://link.springer.com/article/10.1007/s10661-019-7200-2#citeas>. Acesso em: 09 nov. 2024.

LUKAS, Paulos; MELESSE, Assefa M.; KENEA, Tadesse Tujuba. Prediction of Future Land Use/Land Cover Changes Using a Coupled CA-ANN Model in the Upper Omo–Gibe River Basin, Ethiopia. **Remote Sensing**, [S.l.], v. 15, n. 4, p. 1148, 20 fev. 2023. Disponível em: <http://dx.doi.org/10.3390/rs15041148>. Acesso em: 09 nov. 2024.

LUNA, Ivette; SOARES, Secundino; BALLINI, Rosângela. Modelo Adaptativo Baseado Em Regras Nebulosas Aplicado À Previsão De Séries Temporais. **Learning And Nonlinear Models**, [S.l.], v. 5, n. 1, p. 36-50, 2007. Disponível em: <https://sbic.org.br/Inlm/publicacoes/vol5-no1/vol5-no1-art4/>. Acesso em: 09 nov. 2024.

LUNETTA, Camila; PEIXOTO, Magda da Silva. Um modelo de avaliação do processo ensino-aprendizagem via sistemas baseados em regras fuzzy. **Proceeding Series of the Brazilian Society of Computational and Applied Mathematics**, [S.l.], v. 8, n. 1, 2021. Disponível em: <https://proceedings.sbmac.org.br/sbmac/article/view/136277/0>. Acesso em: 09 nov. 2024.

MAHAMUD, M. A.; SAMAT, N.; TAN, M. L.; CHAN, N. W.; TEW, Y. L.. PREDICTION

OF FUTURE LAND USE LAND COVER CHANGES OF KELANTAN, MALAYSIA. **The International Archives Of The Photogrammetry, Remote Sensing And Spatial Information Sciences**, [S./], v. -4/16, p. 379-384, 1 out. 2019. Disponível em: <http://dx.doi.org/10.5194/isprs-archives-xlii-4-w16-379-2019>. Acesso em: 09 nov. 2024.

MANDAL, Jayatra; GHOSH, Nupur; MUKHOPADHYAY, Anirban. Urban Growth Dynamics and Changing Land-Use Land-Cover of Megacity Kolkata and Its Environs. **Journal Of The Indian Society Of Remote Sensing**, [S./], v. 47, n. 10, p. 1707-1725, 12 jul. 2019. Disponível em: <http://dx.doi.org/10.1007/s12524-019-01020-7>. Acesso em: 09 nov. 2024.

MATHANRAJ, S; RUSLI, N; LING, G H T. Applicability of the CA-Markov Model in Land-use/Land cover Change Prediction for Urban Sprawling in Batticaloa Municipal Council, Sri Lanka. **Iop Conference Series: Earth and Environmental Science**, [S./], v. 620, n. 1, p. 012015, 9 jan. 2021. Disponível em: <http://dx.doi.org/10.1088/1755-1315/620/1/012015>. Acesso em: 09 nov. 2024.

MAURYA, Nitesh Kumar; RAFI, Sana; SHAMOO, Saima. Land use/land cover dynamics study and prediction in jaipur city using CA markov model integrated with road network. **Geojournal**, [S./], v. 88, n. 1, p. 137-160, 15 fev. 2022. Disponível em: <https://doi.org/10.1007/s10708-022-10593-9>. Acesso em: 09 nov. 2024.

MCCULLOCH, Warren S. ; PITTS, Walter. A logical calculus of the ideas immanent in nervous activities. *Bulletin of Mathematical Biophysics*, v. 52, n. 1/2, p. 99-115, 1990. Disponível em: <https://www.cs.cmu.edu/~epxing/Class/10715/reading/McCulloch.and.Pitts.pdf>. Acesso em: 09 nov. 2024.

MICHEL, Opelele Omeno; YING, Yu; WENYI, Fan; CHEN, Chen; KAIKO, Kachaka Sudi. Examining Land Use/Land Cover Change and Its Prediction Based on a Multilayer Perceptron Markov Approach in the Luki Biosphere Reserve, Democratic Republic of Congo. **Sustainability**, [S./], v. 13, n. 12, p. 6898, 18 jun. 2021. Disponível em: <http://dx.doi.org/10.3390/su13126898>. Acesso em: 09 nov. 2024.

MORGAN, James N.; SONQUIST, John A.. Problems in the Analysis of Survey Data, and a Proposal. **Journal Of The American Statistical Association**, [S./], v. 58, n. 302, p. 415-434, jun. 1963. Disponível em: <http://dx.doi.org/10.1080/01621459.1963.10500855>. Acesso em: 09 nov. 2024.

MORO, Marcelo Freire; AMORIM, Vivian Oliveira; QUEIROZ, Luciano Paganucci de; COSTA, Luis Ricardo Fernandes da; MAIA, Rubson Pinheiro; TAYLOR, Nigel P.; ZAPPI, Daniela C.. Biogeographical Districts of the Caatinga Dominion: a proposal based on geomorphology and endemism. **The Botanical Review**, [S./], v. 90, n. 4, p. 376-429, 4 out. 2024. Disponível em: <http://dx.doi.org/10.1007/s12229-024-09304-5>. Acesso em: 09 nov. 2024.

NAVIN, M. Sam; AGILANDEESWARI, Loganathan. Multispectral and hyperspectral images based land use / land cover change prediction analysis: an extensive review. **Multimedia Tools and Applications**, v. 79, n. 39–40, p. 29751–29774, 2020.

Disponível em: <https://link.springer.com/article/10.1007/s11042-020-09531-z>. Acesso em: 09 nov. 2024.

NEVES, Eder Pereira; DUARTE, Aparecido Queiroz Marco; ALVARADO, Francisco Villarreal. Sistema baseado em regras fuzzy para avaliação da qualidade da água. **C.Q.D.– Revista Eletrônica Paulista de Matemática**, [S./], v. 14, p. 95–109, 2019. Disponível em: <https://www.fc.unesp.br/#!/departamentos/matematica/revista-cqd/>. Acesso em: 09 nov. 2024.

ODIJI, C. A.; AHMAD, H. S.; ADEPOJU, M. O.; ODIA, B.; HAMZA, D. D.; AKPABIO, W. E.. Analysis and prediction of land use/ land cover changes and its impacts on the corridors of cattle grazing routes in Benue state, Nigeria. **Geology, Ecology, And Landscapes**, [S./], v. 8, n. 4, p. 498-512, 12 dez. 2022. Disponível em: <http://dx.doi.org/10.1080/24749508.2022.2154929>. Acesso em: 09 nov. 2024.

ODY, Magnus Cesar; VIALI, Lori. Stephen e Conrad Wolfram: uma trajetória de contribuições para a Tecnologia e a Matemática. **FACCAT**, [S./], [2016?]. Disponível em: <https://www2.faccat.br/portal/sites/default/files/STEPHEN%20E%20CONRAD%20WOLFRAM.pdf>. Acesso em 19 jan. 2025.

ÖZKALE, M. Revan. Predictive performance of linear regression models. **Statistical Papers**, [S./], v. 56, n. 2, p. 531-567, 2015. Disponível em: <https://link.springer.com/article/10.1007/s00362-014-0596-4#citeas>. Acesso em: 09 nov. 2024.

PANDEY, Soumya; KUMARI, Neeta; NAWAJISH, Shah Al. Land Use Land Cover (LULC) and Surface Water Quality Assessment in and around Selected Dams of Jharkhand using Water Quality Index (WQI) and Geographic Information System (GIS). **Journal Of The Geological Society Of India**, [S./], v. 99, n. 2, p. 205-218, 1 fev. 2023. Disponível em: <http://dx.doi.org/10.1007/s12594-023-2288-y>. Acesso em: 09 nov. 2024.

PEREIRA, Andreia; LAUREANO, Raul M. S.; NETO, Fernando; MACEDO, Joao. Computer simulation of diabetic retinopathy screening adherence: agent based model with fuzzy logic. **2021 16Th Iberian Conference On Information Systems And Technologies (Cisti)**, [S./], p. 1-6, 23 jun. 2021. Disponível em: <http://dx.doi.org/10.23919/cisti52073.2021.9476265>. Acesso em: 09 nov. 2024.

PEREIRA, Gabriel Henrique de Almeida; CENTENO, Jorge Antonio Silva. Avaliação do tamanho de amostras de treinamento para redes neurais artificiais na classificação supervisionada de imagens utilizando dados espectrais e laser scanner. **Boletim de Ciências Geodésicas**, [S./], v. 23, n. 2, p. 268-283, jun. 2017. Disponível em: <http://dx.doi.org/10.1590/s1982-21702017000200017>. Acesso em: 09 nov. 2024.

PERMATASARI, R. J.; DAMAYANTI, A.; INDRA, T. L.; DIMYATI, M. Prediction of land cover changes in Penajam Paser Utara Regency using cellular automata and markov model. **IOP Conference Series: Earth and Environmental Science**, v. 623, n. 1, p. 6–13, 2021. Disponível em: <https://iopscience.iop.org/article/10.1088/1755->

1315/623/1/012005. Acesso em: 09 nov. 2024.

PIGA, Fabíola Geovanna. **Modelagem ambiental de áreas degradadas por processos erosivos, com vista ao planejamento ambiental–São Pedro e Santa Maria da Serra/SP**. 2017. 128 f. Dissertação (Mestrado) - Curso de Programa de Pós-Graduação em Ciências Ambientais, Universidade Federal de São Carlos, São Carlos, 2018. Disponível em: <https://repositorio.ufscar.br/items/e070eb56-4ac5-41e5-9954-ef785c2a013d>. Acesso em: 30 set. 2024.

PINHEIRO, Carlos; GOMIDE, Fernando; CARPINTEIRO, Otávio; LIMA, Isaías. Modelos baseados em conjuntos aproximados. *In*: Congresso Brasileiro de Automática, 18, Bonito-MS. **Anais [...]**. Bonito-MS: [S.l.], 2010. Disponível em: https://www.academia.edu/26001652/Modelos_Baseados_Em_Conjuntos_Aproximados. Acesso em: 09 nov. 2024.

RASAEI, Zahra; BOGAERT, Patrick. Spatial filtering and Bayesian data fusion for mapping soil properties: a case study combining legacy and remotely sensed data in iran. **Geoderma**, [S.l.], v. 344, p. 50-62, jun. 2019. Disponível em: <http://dx.doi.org/10.1016/j.geoderma.2019.02.031>. Acesso em: 09 nov. 2024.

RASOOL, Rehana; FAYAZ, Abida; SHAFIQ, Mifta. Ul; SINGH, Harmeet; AHMED, Pervez. Land use land cover change in Kashmir Himalaya: Linking remote sensing with an indicator based DPSIR approach. **Ecological Indicators**, [S.l.], v. 125, p. 107447, jun. 2021. Disponível em: <http://dx.doi.org/10.1016/j.ecolind.2021.107447>. Acesso em: 09 nov. 2024.

RAUTENBERG, Sandro; CARMO, Paulo Ricardo Viviurka do. Big data e ciência de dados. **Brazilian Journal Of Information Science: research trends**, [S.l.], v. 13, n. 1, p. 56-67, 29 mar. 2019. Disponível em: <https://revistas.marilia.unesp.br/index.php/bjis/article/view/8315>. Acesso em: 09 nov. 2024.

REIS, Artur Cabral; VENTURELLI, Suzete. Híbridos na arte computacional. **Revista Farol**, [S.l.], n. 22, p. 37-47, 26 out. 2020. Disponível em: <https://periodicos.ufes.br/farol/article/view/30918>. Acesso em: 09 nov. 2024.

ROUSHANGAR, Kiyoumars; AALAMI, Mohammad Taghi; GOLMOHAMMADI, Hassan; SHAHNAZI, Saman. Monitoring and prediction of land use/land cover changes and water requirements in the basin of the Urmia Lake, Iran. **Water Supply**, [S.l.], v. 23, n. 6, p. 2299-2312, 2023. Disponível em: <http://dx.doi.org/10.2166/ws.2023.132>. Acesso em: 09 nov. 2024.

SAMPAIO, Gilson Aparecido; FERREIRA, Wanyr Romero; BAHIA, Eduardo Trindade; HENKES, Jairo Afonso. Fontes Renováveis: Análise Dinâmica De Sistemas Aplicada À Matriz Energética Do Brasil. **Revista Gestão & Sustentabilidade Ambiental**, [S.l.], v. 9, n. 3, p. 438, 2020. Disponível em: https://portaldeperiodicos.animaeducacao.com.br/index.php/gestao_ambiental/article/view/5715/0. Acesso em: 09 nov. 2024.

SANTANA, John Kennedy Ribeiro de. **Aplicação do Modelo Hierárquico Analítico**

(AHP) na previsão das áreas de perigo a escorregamentos em Recife (PE).

2020. 133 f. Dissertação (Doutorado) - Curso de Geografia, Universidade Federal de Pernambuco, Recife, 2020. Disponível em:
<https://repositorio.ufpe.br/handle/123456789/38842>. Acesso em: 30 set. 2024.

SANTOS FILHO, Edval Carlos dos. **Modelo baseado em Agentes para Avaliação de Políticas Públicas de Segurança.** 2023. 129 f. Tese (Doutorado) - Curso de

Modelagem Computacional e Tecnologia Industrial, Senai Cimatec, Salvador, 2023. Disponível em: chrome-

extension://efaidnbmnnnibpcajpcgiclfndmkaj/<http://repositoriosenaiba.fieb.org.br/bitstream/fieb/1879/1/EDVAL%20CARLOS%20DOS%20SANTOS%20FILHO.pdf>.

Acesso em: 30 nov. 2024.

SANTOS, Wharley P. dos; ACUÑA-GUZMAN, Salvador F.; OLIVEIRA, Paulo T. S. de; BENIAICH, Adnane; CARDOSO, Dione P.; SILVA, Marx L. N.; CURI, Nilton; AVANZI, Junior C. CA-Markov prediction modeling for the assessment of land use/land cover change in two sub-basins of the Tocantins-Araguaia River Basin.

Environmental Monitoring and Assessment, [S.l.], v. 196, n. 6, 2024. Springer International Publishing. Disponível em: <https://doi.org/10.1007/s10661-024-12673-4>. Acesso em: 09 nov. 2024.

SILVA, Diego Vicente Sperle da; CRUZ, Carla Bernadete Madureira. Tipologias de Caatinga: Uma Revisão em Apoio a Mapeamentos Através de Sensoriamento Remoto Orbital e GEOBIA. **Geography Department University Of Sao Paulo**, [S.l.], v. 35, p. 113-120, 24 jul. 2018. Disponível em:

<http://dx.doi.org/10.11606/rdg.v35i0.142710>. Acesso em: 09 nov. 2024.

SILVA, Icaro Breno; MENDES, Lúcia Maria Silveira. Mapping of Areas Susceptible to Erosion Laminar in the Upper Course of the River Bababuiu-Ce. **Revista Geoaraguaia**, [S.l.], v. 9, n. 2, p. 48–64, 2019. Disponível em:

<https://periodicoscientificos.ufmt.br/ojs/index.php/geo/article/view/8970>. Acesso em: 09 nov. 2024.

SILVA, Jadielle Lidianne Clemente; VIDAL, Carlos Alberto Soares; BARROS, Luiz Marivando; FREITA, Francisco Ronaldo Vieira. Aspectos da Degradação Ambiental no Nordeste do Brasil. **Revista Gestão & Sustentabilidade Ambiental**, [S.l.], v. 7, n. 2, p. 180, 27 abr. 2018. Disponível em: <http://dx.doi.org/10.19177/rgsa.v7e22018180-191>. Acesso em: 09 nov. 2024.

SILVA, Lucas da; LIMA, Eduardo Rodrigues Viana de. Índice de Sustentabilidade da Dimensão Ambiental da Bacia Hidrográfica do Rio Banabuiú, CE. **Espaço Aberto**, [S.l.], v. 7, n. 1, p. 71–85, 2017. Disponível em:

<https://doi.org/10.36403/espacoaberto.2017.5183>. Acesso em: 09 nov. 2024.

SINGH, Bhavna; VENKATRAMANAN, Veluswamy; DESHMUKH, Benidhar.

Monitoring of land use land cover dynamics and prediction of urban growth using Land Change Modeler in Delhi and its environs, India. **Environmental Science and Pollution Research**, [S.l.], v. 29, n. 47, p. 71534–71554, 2022. Springer Berlin Heidelberg. Disponível em: <https://doi.org/10.1007/s11356-022-20900-z>. Acesso em: 09 nov. 2024.

SOBCZAK, Jéssica Carvalho; BORGES, Cosme Polese; VAZ, Caroline Rodrigues. Utilizando um Modelo de Dinâmica de Sistemas para analisar os cenários do potencial de Biogás no Brasil. In: Encontro Internacional sobre Gestão Empresarial e Meio Ambiente (ENGEMA), 21, São Paulo. **Anais [...]**. São Paulo: USP, 2019.

Disponível em:

https://engemausp.submissao.com.br/21/anais/resumo.php?cod_trabalho=152.

Acesso em: 12 nov. 2024.

STORY, Michael; CONGALTON, Russel G. Remote Sensing Brief : Accuracy Assessment: A User's Perspective. **Photogrammetric Engineering and Remote Sensing**, Bekerley, v. 52, n. 3, p. 397–399, 1986. Disponível em:

https://www.asprs.org/wp-content/uploads/pers/1986journal/mar/1986_mar_397-399.pdf. Acesso em: 09 nov. 2024.

SUNDAR, Parthasarathy Kulithalai Shiyam; DEKA, Paresh Chandra. Spatio-temporal classification and prediction of land use and land cover change for the Vembanad Lake system, Kerala: a machine learning approach. **Environmental Science and Pollution Research**, [S.l.], v. 29, n. 57, p. 86220–86236, 2022. Disponível em:

<https://doi.org/10.1007/s11356-021-17257-0>. Acesso em: 09 nov. 2024.

TAJBAKSH, S.M.; MEMARIAN, H.; KHEYRKHAH, A.. A GIS-based integrative approach for land use optimization in a semi-arid watershed. **Global Journal Of Environmental Science And Management**, [S.l.], v. 4, n. 1, p. 31-46, jan. 2018.

Disponível em: <https://doi.org/10.22034/gjesm.2018.04.01.004>. Acesso em: 09 nov. 2024.

TRITSCH, Isabelle; DAS CHAGAS VASCONCELOS JÚNIOR, Francisco; LINHARES, Samiramisthais; ALVES, Rafaela; DEHON DE ARAÚJO PONTES FILHO, João; NASCIMENTO, Rousilene; ALVARENGA, Iago; LEITE, Nicolly; SAKAMOTO, Meiry Sayuri; SÍLVIA BENÍCIO DE SOUZA CARVALHO, Margareth; VIEIRA ROCHA, Renan; BURTE, Julien; SCOPEL, Eric; SÁVIO PASSOS RODRIGUES MARTINS, Eduardo. Nexus water, agriculture, caatinga for territorial water governance. In: Simpósio Brasileiro de Recursos Hídricos, 25, 2023, Aracaju. **Anais [...]**. Aracaju: Centro de Convenções AM Malls, 2023, p. 1–8. Disponível em: <https://anais.abrhidro.org.br/job.php?Job=15693>. Acesso em: 09 nov. 2024.

VAZ, Caroline Rodrigues; INOMATA, Danielly Oliveira; MALDONADO, Mauricio Uriona. Aplicações de Dinâmica de Sistemas na Logística Reversa: uma análise bibliométrica. **Revista Gestão da Produção Operações e Sistemas**, [S.l.], v. 11, n. 4, p. 101-101, 1 nov. 2016. Disponível em:

<https://revista.feb.unesp.br/gepros/article/view/1551>. Acesso em: 09 nov. 2024.

WALJEE, Akbar K.; HIGGINS, Peter D. R.; SINGAL, Amit G. A primer on predictive models. **Clinical and Translational Gastroenterology**, [S.l.], v. 5, n. 12, p. e44-4, 2014. Disponível em: <http://dx.doi.org/10.1038/ctg.2013.19>. Acesso em: 09 nov. 2024.

WANG, Qingzheng; GUAN, Qingyu; LIN, Jinkuo; LUO, Haiping; TAN, Zhe; MA, Yunrui. Simulating land use/land cover change in an arid region with the coupling

models. **Ecological Indicators**, [S./], v. 122, p. 107231, mar. 2021. Disponível em: <http://dx.doi.org/10.1016/j.ecolind.2020.107231>. Acesso em: 09 nov. 2024.

WU, Ke; ZHONG, Yanfei; WANG, Xianmin; SUN, Weiwei. A Novel Approach to Subpixel Land-Cover Change Detection Based on a Supervised Back-Propagation Neural Network for Remotely Sensed Images With Different Resolutions. **Ieee Geoscience And Remote Sensing Letters**, [S./], v. 14, n. 10, p. 1750-1754, out. 2017. Disponível em: <http://dx.doi.org/10.1109/lgrs.2017.2733558>. Acesso em: 09 nov. 2024.

XIONG, Nina; YU, Rongxia; YAN, Feng; WANG, Jia; FENG, Zhongke. Land Use and Land Cover Changes and Prediction Based on Multi-Scenario Simulation: a case study of qishan county, china. **Remote Sensing**, [S./], v. 14, n. 16, p. 4041-4041, 19 ago. 2022. Disponível em: <https://doi.org/10.3390/rs14164041>. Acesso em: 09 nov. 2024.

XU, Dehe; ZHANG, Ke; CAO, Lianhai; GUAN, Xiangrong; ZHANG, Hengbin. Driving forces and prediction of urban land use change based on the geodetector and CA-Markov model: a case study of zhengzhou, china. **International Journal Of Digital Earth**, [S./], v. 15, n. 1, p. 2246-2267, 19 dez. 2022. Disponível em: <http://dx.doi.org/10.1080/17538947.2022.2147229>. Acesso em: 09 nov. 2024.

YANG, Runjia; CHEN, Hong; CHEN, Sha; YE, Yanmei. Spatiotemporal evolution and prediction of land use/land cover changes and ecosystem service variation in the Yellow River Basin, China. **Ecological Indicators**, [S./], v. 145, n. 1, p. 109579, dez. 2022. Disponível em: <http://dx.doi.org/10.1016/j.ecolind.2022.109579>. Acesso em: 09 nov. 2024.

YU, Ping; ZHANG, Shuainan; WANG, Peng; LI, Yingnan; HUANG, Lei. Evaluation and prediction of land use change impacts on ecosystem service values in Nanjing City from 1995 to 2030. **Environmental Science And Pollution Research**, [S./], v. 30, n. 7, p. 18040-18063, 7 out. 2022. Disponível em: <http://dx.doi.org/10.1007/s11356-022-23346-5>. Acesso em: 09 nov. 2024.

YUAN, Hui; WIELE, Cynthia F. van Der; KHORRAM, Siamak. An Automated Artificial Neural Network System for Land Use/Land Cover Classification from Landsat TM Imagery. **Remote Sensing**, [S.L.], v. 1, n. 3, p. 243-265, 9 jul. 2009. Disponível em: <http://dx.doi.org/10.3390/rs1030243>. Acesso em: 09 nov. 2024.

ZAMBON, Antonio Carlos; PEREIRA, Néocles Alves; POLITANO, Paulo Rogério; DELGADO, Sven Schäfers. Validação e fidedignidade de modelos de dinâmica de sistemas. *In*: SIMPEP, 13, Bauru. **Anais [...]**, Bauru: UNESP, 2006, p. 1–12. Disponível em: file:///C:/Users/bea_f/Downloads/Validacao_e_fidedignidade_de_modelos_de_dinamica_d.pdf. Acesso em: 09 nov. 2024.

ZHANG, Shengqing; YANG, Peng; XIA, Jun; WANG, Wenyu; CAI, Wei; CHEN, Nengcheng; HU, Sheng; LUO, Xiangang; LI, Jiang; ZHAN, Chesheng. Remote sensing inversion and prediction of land use land cover in the middle reaches of the Yangtze River basin, China. **Environmental Science And Pollution Research**,

[S./], v. 30, n. 16, p. 46306-46320, 31 jan. 2023. Disponível em:
<http://dx.doi.org/10.1007/s11356-023-25424-8>. Acesso em: 09 nov. 2024.