

CRISTIANO MORAES CAMPOS SANTOS

**TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA O MAPEAMENTO DAS  
FITOFISIONOMIAS DA CAATINGA DA TERRA INDÍGENA CAIÇARA/ILHA DE  
SÃO PEDRO**

SÃO CRISTÓVÃO - SE

2024

Cristiano Moraes Campos Santos

**TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA O MAPEAMENTO DAS  
FITOFISIONOMIAS DA CAATINGA DA TERRA INDÍGENA CAIÇARA/ILHA DE  
SÃO PEDRO**

Trabalho de conclusão de curso apresentado ao  
Departamento de Ciências Florestais,  
Universidade Federal de Sergipe, como requisito  
parcial para obtenção do título de Engenheiro  
Florestal.

SÃO CRISTÓVÃO - SE

2024



UNIVERSIDADE FEDERAL DE SERGIPE – UFS  
CENTRO DE CIÊNCIAS AGRÁRIAS APLICADAS – CCAA  
DEPARTAMENTO DE CIÊNCIAS FLORESTAIS – DCF

**TÉCNICAS DE APRENDIZADO DE MÁQUINA PARA O MAPEAMENTO DAS  
FITOFISIONOMIAS DA CAATINGA DA TERRA INDÍGENA CAIÇARA/ILHA DE  
SÃO PEDRO**

Trabalho de conclusão de curso apresentado ao  
Departamento de Ciências Florestais,  
Universidade Federal de Sergipe, como requisito  
parcial para obtenção do título de Engenheiro  
Florestal.

Aprovado em: 18/10/2024

Discente: Cristiano Moraes Campos Santos

---

Prof. Dr. Diego Campana Loureiro  
(Orientador)

---

Profa. Dra. Anna Carolina De Almeida  
Andrade  
(Examinadora)

---

Prof. Dr. André Quintão De Almeida  
(Examinador)

## AGRADECIMENTOS

In memoriam a minha mãe, Ibelza Moraes Campos Santos, que sempre acreditou nesse momento. Sua fé em mim foi a luz que me guiou ao longo desta jornada, e cada conquista é, em essência, também sua. Embora não esteja fisicamente presente, sinto sua força e seu amor em cada passo que dou. Este trabalho é dedicado à sua memória, com eterna gratidão e saudade.

Agradeço aos meus familiares, que sempre me apoiaram de forma incondicional, e aos amigos da Escola Agrotécnica Federal de São Cristóvão, que fizeram parte do início dessa caminhada. Àqueles que conheci na universidade, na EMBRAPA e na ABEEF, minha sincera gratidão pelas trocas de conhecimento e pelas amizades construídas.

Agradeço também à turma da Mombaça, ao Instituto Pangea, às catadoras de mangaba, e ao povo Xokó, que me ensinaram lições valiosas que levarei para a vida. E, por fim, deixo um agradecimento especial aos meus amigos da EMDAGRO, que com paciência e compreensão me acompanharam e me apoiaram nessa fase final.

**Resumo:**

Título: Técnicas de aprendizado de máquina para o mapeamento das fitofisionomias da Caatinga na Terra Indígena Caiçara/Ilha de São Pedro

**Resumo:**

Este trabalho aplicou técnicas de aprendizado de máquina para o mapeamento das fitofisionomias da Caatinga na Terra Indígena Caiçara/Ilha de São Pedro, em Sergipe, habitada pelo povo Xokó. Foram utilizadas imagens do satélite CBERS 04A e testados três algoritmos de classificação supervisionada: Random Forest (RF), Support Vector Machine (SVM) e Redes Neurais (RN). O objetivo foi avaliar o desempenho desses algoritmos na identificação das formações vegetais da região. O RF destacou-se com uma acurácia de 95,93%, sendo o mais eficaz na distinção das fitofisionomias. As classes mapeadas incluíram Savana Estépica Florestada, Savana Estépica Arborizada, Savana Estépica Parque, Savana Estépica Gramíneo-Lenhosa, Savana Estépica Florestada com Maciço de Jurema e áreas de agricultura. A pesquisa demonstrou a eficiência do aprendizado de máquina no monitoramento ambiental e gestão territorial, reforçando a importância da tecnologia para a conservação do bioma Caatinga. Além disso, destacou o papel essencial da comunidade indígena Xokó na preservação sustentável de seu território, equilibrando práticas tradicionais com a proteção ambiental

**Palavras-chave:** Random Forest, Sensoriamento Remoto, conservação ambiental, SupportVectorMachine, Redes Neurais.

## SUMÁRIO

1.	INTRODUÇÃO .....	12
2.	REVISÃO BIBLIOGRAFICA.....	13
2.1.	Fitofisionomia vegetal no bioma Caatinga.....	13
2.2.	Territórios Indígenas e a Terra Idigena Caiçara/Ilha de São Pedro.....	17
2.3.	Aplicação de SIG e Sensoriamento Remoto no Mapeamento das Fitofisionomias da Caatinga.....	20
3.	MATERIAIS E METODOS.....	24
3.1.	Área de estudo.....	24
3.2.	Clima .....	24
3.3.	Vegetação.....	25
3.4.	Relevo .....	26
3.5.	Economia .....	27
3.6.	Fluxograma metodológico .....	28
3.7.	Obtenção de Dados.....	28
3.8.	Técnicas de Aprendizado de Máquina (métodos de classificação).....	30
3.8.1.	Amostras de treinamento .....	30
3.8.2.	Random Forest (RF).....	31
3.8.3.	Support Vector Machine (SVM).....	31
3.8.4.	Redes Neurais (RN).....	32
3.9.	Classes Mapeadas.....	32
3.10.	Software utilizados.....	35
3.11.	Validação da classificação .....	35
4.	RESULTADOS E DISCUSSÃO.....	36
5.	CONCLUSÃO .....	43
6.	REFERÊNCIAS.....	44

## FIGURAS

Figura 1 - Mapa Geografico do Bioma Caatinga.....	14
Figura 2: Ilustração dos subgrupos da vegetação de savanas-estépicas.....	16
Figura 3: Mapa de localização da Terra Indígena Caiçara/Ilha de São Pedro. ....	24
Figura 4: Imagem SRTM (Shuttle Radar Topography Mission) representando o Modelo Digital da Terra Indígena Caiçara/Ilha De São Pedro .....	26
Figura 5: Mapa de declividade da Terra Indígena Caiçara/Ilha de São Pedro.....	27
Figura 6: Fluxograma metodológico. ....	28
Figura 7 - MAPA Terra Indígena Caiçara/Ilha de São Pedro CBERS 4A sensor WPM, data de passagem 08/10/2020. ....	29
Figura 8 - Distribuição espacial das amostras pontuais de treinamento para cada fitofisionomia da Caatinga.....	31
Figura 9: Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Savana Estépica Florestada (A) e Savana Estépica Parque (B).....	32
Figura 10 - Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Savana Estépica Arborizada (A) e Savana Estépica Florestada + Maciço De Jurema (B).....	33
Figura 11 - Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Agricultura (A) E Savana Estépica Gramíneo-Lenhosa (B).....	33
Figura 12 - Diferentes fitofisionomias mapeadas na imagem CBERS 4A composição RGB e sua respectiva foto no campo.....	34
Figura 13: Mapa de Fitofisionomias gerado pelo classificador Randon Forest na Terra Indígena Caiçara / Ilha de São Pedro. ....	42
Figura 14 - Porcentagem de Fitofisionomias gerada pelo classificador Randon Forest na Terra Indígena Caiçara / Ilha de São Pedro.....	43

## TABELAS

Tabela 1: Principais características da Câmera Wide Panchromatic Multispectral (WPM) do satélite CBERS 04A. ....	21
Tabela 2 - Matriz de confusão dos algoritmos Redes Neurais da classificação das fitofisionomias da Caatinga.....	37
Tabela 3 - Matriz de confusão dos algoritmos Random Forest da classificação das fitofisionomias da Caatinga.....	38
Tabela 4 - Matriz de confusão do algoritmo support vector machine da classificação das fitofisionomias da Caatinga.....	39
Tabela 5- Resultados da Acurácia, Índice De Kappa e Índice De Tau de Acordo com os Classificadores. ....	40

## 1. INTRODUÇÃO

A Caatinga é um bioma que é único do Brasil e é reconhecida por ser a única savana do país. Distingue-se por ser uma vegetação, que se adaptou às condições climáticas do semiárido, sendo o único tipo de cobertura vegetal capaz de suportar as condições climáticas severas da região, que incluem altas temperaturas do ar, períodos prolongados de seca, e solos rasos e com baixo teor de matéria orgânica (Freire et al., 2020; Pinho et al., 2020). É caracterizada por uma rica diversidade de fitofisionomias adaptadas a ambientes de baixa umidade.

Fitofisionomias referem-se às diferentes formas e estruturas que a vegetação assume em um determinado ambiente. Esse conceito é utilizado para descrever e classificar as características visuais e estruturais das coberturas vegetais em um determinado ecossistema. Ajudam a identificar e compreender os padrões de vegetação em diferentes tipos de ambientes e ecossistemas, oferecendo insights sobre a saúde ecológica, a dinâmica dos habitats e as influências ambientais que moldam essas características (Larcher, 2001).

A terra indígena Caiçara/Ilha de São Pedro está localizada no município de Porto da Folha, no estado de Sergipe, é guardada e habitada pelo Povo Xokó e representa um ecossistema de importância ecológica e cultural significativa. A preservação e a gestão eficaz desta terra exigem uma compreensão detalhada das fitofisionomias que compõem a vegetação local, bem como uma capacidade de monitorar e mapear essas formações vegetais com precisão (FUNAI/ANAI, 2017).

Tradicionalmente, o mapeamento da vegetação tem sido realizado por meio de métodos de campo e análises fotográficas aéreas ou satélites. No entanto, esses métodos enfrentam limitações em termos de precisão, escala e eficiência, especialmente em áreas remotas e de difícil acesso. Com o avanço das tecnologias de aprendizado de máquina, surgem novas oportunidades para superar essas limitações e melhorar a qualidade e a eficiência do mapeamento da vegetação (Alba et al., 2022).

Um exemplo recente é o satélite CBERS 04A, lançado através da parceria entre Brasil e China. Esse satélite oferece imagens multiespectrais de alta resolução, essenciais para o monitoramento ambiental em áreas extensas e de difícil acesso (INPE, 2024). Combinando dados do CBERS 04A e técnicas avançadas de aprendizado de máquina, é possível aumentar significativamente a precisão do mapeamento e realizar análises mais eficientes e detalhadas, especialmente em áreas críticas para a conservação.

Técnicas modernas de aprendizado de máquina, como Redes Neurais, Random Forest e Support Vector Machine, têm se destacado em diversas aplicações de análise de dados e reconhecimento de padrões devido à sua capacidade de lidar com grandes volumes de dados e identificar complexas relações entre variáveis. No contexto do mapeamento da vegetação, essas técnicas oferecem promissora capacidade para melhorar a classificação e a distinção das diferentes formações vegetais, aproveitando dados obtidos por sensores remotos e imagens de satélite (Venturieri & Santos, 1998).

Ao utilizar técnicas avançadas de aprendizado de máquina para o mapeamento da fitofisionomia da Caatinga, esperamos não apenas melhorar a compreensão e a representação das características vegetativas do território, mas também estabelecer uma base para futuras pesquisas e práticas de manejo sustentável em áreas semelhantes.

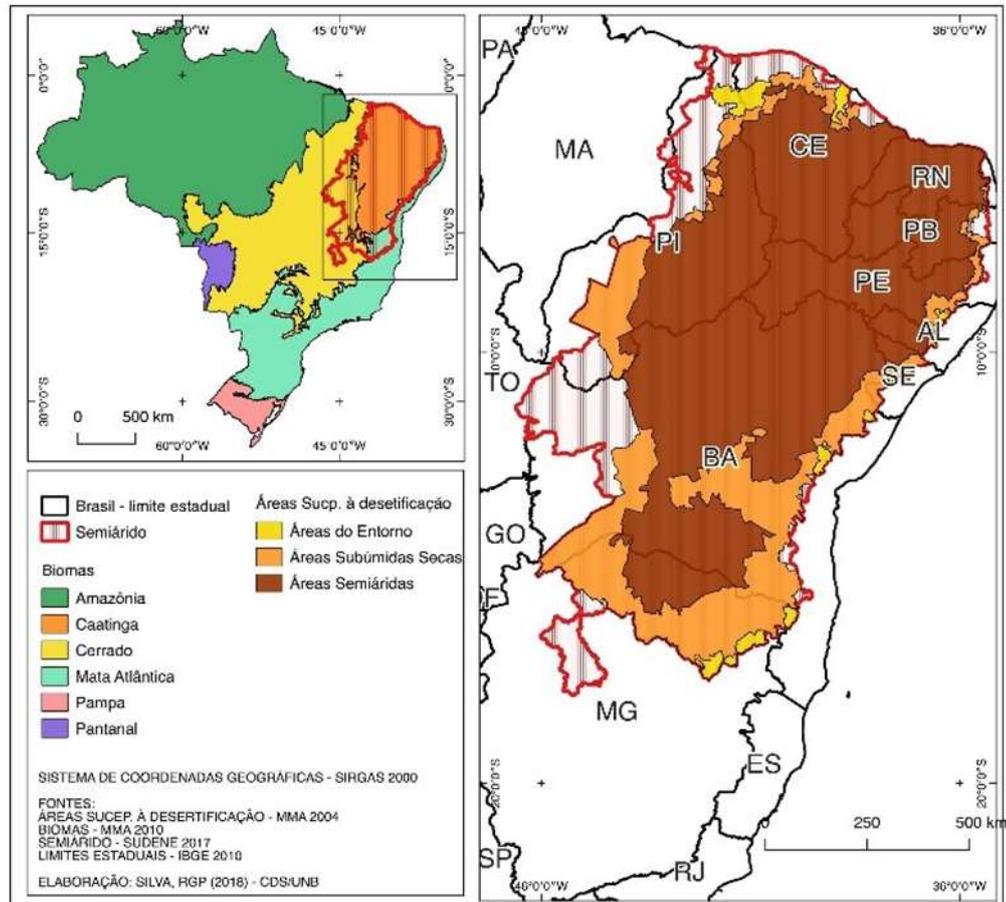
Este trabalho visa explorar e avaliar o desempenho de diferentes técnicas de aprendizado de máquina no mapeamento das fitofisionomias da Caatinga na terra indígena Caiçara/Ilha de São Pedro. A análise comparativa dessas técnicas permite identificar qual abordagem proporciona excelentes resultados em termos de precisão e eficiência, fornecendo informações valiosas para a gestão e conservação do bioma. A integração de técnicas de aprendizado de máquina neste contexto pode contribuir para um monitoramento mais eficaz e para a elaboração de estratégias de preservação adaptadas às condições específicas da região.

## **2. REVISÃO BIBLIOGRAFICA**

### **2.1. Fitofisionomia vegetal no bioma Caatinga**

O bioma Caatinga é considerado um dos ecossistemas mais distintos e menos compreendidos do território brasileiro. A Caatinga, que abrange uma ampla região do Nordeste do país, com mais de 800 mil quilômetros quadrados (Figura 1), é conhecida por sua paisagem árida onde os solos são rasos e pedregosos e pobres em matéria orgânica, influenciando a composição e estrutura da vegetação, adaptadas a suportar longos períodos de secas e condições adversas (Freire et al., 2020).

Figura 1 - Mapa Geográfico do Bioma Caatinga



Fonte: INCT-Odisseia ,2024.

Diversas pesquisas científicas têm fundamentado a importância de conservar e aumentar a cobertura vegetal devido a seus impactos positivos para o meio ambiente. A presença da cobertura vegetal, desempenha um papel vital na proteção do solo contra a erosão (Souza et al.,2018). Isto é atribuído principalmente à função de ancoragem realizada pelas raízes das plantas, que mitigam efetivamente a perda de nutrientes e a degradação do solo. Além disso, a vegetação assume uma função principal na regulação do ciclo da água, atuando como uma “esponja verde”, absorvendo efetivamente a precipitação e mitigando a ocorrência de inundações e escassez de água durante períodos de seca (Silva et al., 2019).

Pereira et al. (2020) realizaram um estudo que enfatiza a importância da cobertura vegetal na mitigação das alterações climáticas. O estudo sublinha a capacidade das plantas de sequestrar o carbono, convertendo o dióxido de carbono (CO<sub>2</sub>) em biomassa e oxigênio (O<sub>2</sub>). Além disso, a presença de cobertura vegetal é um fator crucial na promoção da biodiversidade, servindo como habitat e fonte de alimento para uma variedade diversificada de espécies (Araújo et al., 2017). Por conseguinte, a preservação e o aumento da vegetação

são imperativos para a promoção da sustentabilidade ambiental e a manutenção do equilíbrio ecológico.

Embora as condições ambientais sejam áridas, a região da Caatinga apresenta uma notável diversidade biológica. Esta região abriga uma variedade de espécies de fauna e flora que se adaptaram às suas condições adversas. Uma quantidade específica dessas espécies apresenta endemismo, caracterizando-se pela sua ocorrência exclusivamente na região da Caatinga (Cruz, 2019).

O bioma Caatinga, tradicionalmente visto como uma região árida e homogênea, é na verdade um mosaico de paisagens diversificadas, como destaca Fioravanti (2024). Em um estudo recente, propõe-se uma nova reclassificação da Caatinga em 12 subunidades biogeográficas, levando em consideração a distribuição de espécies endêmicas e as características do solo. Essa abordagem inovadora revela a diversidade de ambientes, desde florestas úmidas a áreas com solos pedregosos, mostrando que a Caatinga abriga uma biodiversidade única e regionalizada, o que reflete sua importância ecológica e a necessidade de conservação.

A classificação da tipologia vegetal do bioma Caatinga é essencial para compreensão e conservação deste ecossistema, pois ajuda no processo de identificação de áreas prioritárias para a conservação e desenvolvimento de práticas de manejo sustentável. De acordo com o “Manual Técnico da Vegetação Brasileira” (2012) a vegetação do bioma a caatinga é frequentemente considerada uma savana-estépica devido às suas características ecológicas que combinam elementos típicos de savanas e estepes.

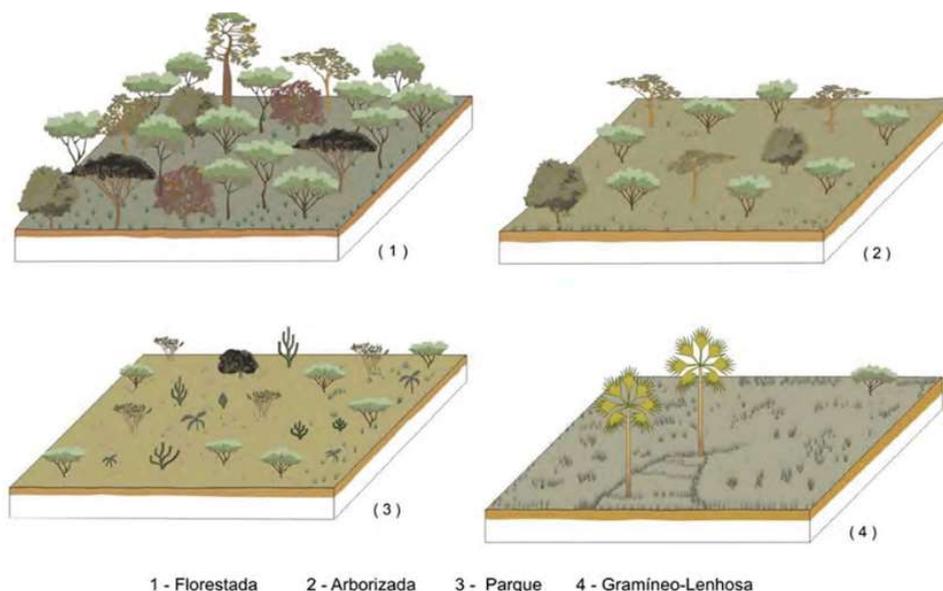
A caatinga apresenta uma vegetação adaptada as condições de baixa umidade e longos períodos de seca (Rodal et al., 2008). Semelhante às savanas, a caatinga possui uma cobertura arbórea esparsa com árvores de pequeno porte e arbustos, intercalada com uma camada herbácea que pode se tornar densa durante as épocas de chuva. Entretanto, as condições áridas da caatinga se assemelham mais às estepes, com um regime de precipitação irregular e solo árido(Sampaio et al., 1995).

De acordo com o “Manual Técnico da Vegetação Brasileira” (IBGE, 2012) a caatinga é uma transição entre a savana e a estepe, refletindo uma combinação das características de ambos os biomas em um ambiente semiárido.Na classificação da vegetação de savanas-estépicas, podem ser identificados diversos subgrupos, esses subgrupos evidenciam a complexidade e a adaptação das savanas-estépicas às condições ambientais e edáficas

variáveis, demonstrando a rica diversidade estrutural dentro desse bioma, cada um refletindo a variação na estrutura e dominância das camadas vegetais podendo ser observado na (IBGE, 2012. Figura 2):

- **Florestada**- é caracterizado por uma vegetação mais densa e contínua, onde as árvores formam uma cobertura relativamente fechada, embora ainda menos densa do que nas florestas tropicais. Nesse subgrupo, as copas das árvores podem se sobrepor, criando um ambiente mais sombreado, mas sem alcançar a densidade de uma floresta densa.
- **Arborizada**- é dominado por árvores de porte médio baixo, que estão espaçadas e possuem copas amplas. Este arranjo permite uma penetração significativa de luz no solo, promovendo uma vegetação herbácea subjacente.
- **Parque** - é caracterizado por uma mistura equilibrada entre árvores espaçadas e uma camada herbácea densa, às árvores, geralmente de porte médio e com copas não sobrepostas, são intercaladas com uma vegetação herbácea robusta, resultando em uma estrutura de vegetação que lembra um parque natural.
- **Gramíneo-lenhosa**- é caracterizado por uma combinação de gramíneas predominantes e vegetação lenhosa, incluindo arbustos e pequenas árvores. Neste subgrupo, as gramíneas dominam a cobertura do solo, enquanto a vegetação lenhosa fornece uma estrutura adicional e contribui para a diversidade da vegetação.

Figura 2: Ilustração dos subgrupos da vegetação de savanas-estépicas



Fonte: IBGE, 2012.

A classificação da caatinga em subgrupos é fundamental para compreender as dinâmicas ecológicas, guiar estratégias de conservação e manejo, monitorar mudanças ambientais, e planejar o uso sustentável da terra. Cada subgrupo apresenta características específicas que influenciam a biodiversidade e a interação dos componentes do bioma, permitindo identificar áreas críticas para preservação e usos adequados para atividades humanas (Silva et al., 2017). Além disso, essa classificação facilita a educação ambiental e a sensibilização pública, reforçando a importância da caatinga como um bioma diverso e valioso.

A Caatinga é confrontada por uma variedade de ameaças que têm um impacto significativo em sua cobertura vegetal e biodiversidade. A principal ameaça reside na conversão de terras para fins agrícolas, pecuários e de desenvolvimento urbano. A atividade de desmatamento e a subsequente fragmentação do habitat têm um impacto negativo significativo na integridade ecológica da região (de Jesus, 2019). Além disso, a exploração inadequada dos recursos hídricos contribui para a degradação dos ecossistemas.

A conservação da Caatinga é fundamental para salvaguardar sua biodiversidade. Diversas iniciativas estão atualmente em curso com o objetivo de abordar essas questões. Uma das estratégias de conservação consiste na implementação de unidades de conservação e áreas protegidas, tais como parques nacionais e reservas naturais, com o objetivo de salvaguardar ecossistemas de relevância (Olivera et al., 2019). Além disso, programas de restauração e gestão sustentável devem ser implementados para mitigar os impactos negativos.

A Caatinga é um bioma diferenciado e valioso que merece atenção e esforços de conservação. A tipologia vegetal e a biodiversidade da região são notáveis, apesar dos desafios enfrentados devido às condições áridas (Leal et al. 2005). A proteção deste ecossistema necessita da colaboração de governos, organizações não governamentais e comunidades locais para garantir um futuro sustentável para a Caatinga e suas numerosas espécies endêmicas (Pereira et al., 2021).

## **2.2. Territórios Indígenas e a Terra Indígena Caiçara/Ilha de São Pedro**

Os territórios indígenas têm desempenhado um papel significativo na conservação e preservação ambiental em todo o mundo. Essas áreas são extremamente ricas em

biodiversidade e são mantidas por comunidades indígenas que têm uma relação profunda com a natureza, atuando como agentes de conservação e preservação ambiental (Pinna, 2020).

Ao longo da história, os territórios indígenas desenvolveram uma profunda reverência pelo mundo natural, integrando os princípios de utilização sustentável da terra com a gestão responsável dos recursos naturais através de suas tradições culturais e conhecimento ecológico local (Júnior et al., 2021). Estas áreas têm papel importante na conservação ambiental, abrigando uma variedade de espécies e ecossistemas que desempenham um papel crucial na manutenção do equilíbrio ecológico global.

Os territórios indígenas desde sempre enfrentam diversos desafios, como invasões, exploração de recursos naturais e mudanças climáticas. Esses desafios ameaçam tanto a cultura quanto a biodiversidade presente nessas comunidades (Santos et al., 2022).

No Brasil o processo de reconhecimento das terras indígenas foi marcado por um longo período de diversos conflitos na história do país. Desde o início da colonização, as terras indígenas foram invadidas e mal apropriadas. Em Sergipe os Xokós foram o primeiro grupo indígena remanescente do estado de Sergipe, vivem na Terra Indígena Caiçara/Ilha de São Pedro localizado em Porto da Folha. A história de luta dos Xokós pelas suas terras começa com a fundação de aldeamentos jesuítas no vale do Rio São Francisco durante o período de colonização (FUNAI/ANAI, 2017).

Na Constituição de 1824 o Estado estabeleceu a tutela sobre as terras indígenas, mas não assegurou a demarcação e segurança efetiva, proporcionando a invasão e ocupação de vários territórios nesse período. A política de assimilação e integração dos povos indígenas foi adotada pelo governo brasileiro, e conseqüentemente, os Xokós foram dispersos pelos antigos aldeamentos onde viviam. Com o tempo, as terras da Ilha de São Pedro, ocupadas pelos Xokós, foram aforadas para João Fernandes de Brito em 1888 pela Câmara de Ilha do Ouro. No entanto, a posse das terras dos Brito ocasionou a expulsão dos Xokós de suas terras. A realidade dos Xokós muda, e a partir daí eles se tornam meeiros para os fazendeiros. Em meio a essa nova realidade, as dificuldades foram muitas, mas o povo Xokós tinha um desejo em comum: a reconquista de suas terras (Lima, 2021).

Já no Código Civil de 1916 ficou permitido a venda de terras indígenas, intensificando a perda desses territórios. Em 1930 no governo de Getúlio Vargas surgiu a criação do Serviço de Proteção ao Índio (SPI), órgão responsável por lidar com questões indígenas na época, mas o órgão acabou sendo marcado por corrupção e negligência. Durante

o regime militar, a Lei de Terras de 1964 enfraqueceu ainda mais os direitos indígenas permitindo a venda de terras indígenas. A Lei 6.001/1973 (Estatuto do Índio) tratou da proteção dos direitos indígenas, mas não impediu a invasão de terras. Na década de 1970, os Xokós lutam para ter de volta suas terras adquirindo o apoio da igreja católica, outras organizações e ONG's.(Dantas, 1997).

A Constituição Federal de 1988 estabeleceu um marco importante ao reconhecer o direito dos povos indígenas à posse permanente de suas terras. Ela determinou que a demarcação das terras indígenas é de responsabilidade do governo federal. Um movimento indígena, indigenista, é criado e finalmente no governo Fernando Collor de Mello, em 1991, a luta dos Xokós foi recompensada, pois suas terras foram oficialmente reconhecidas (Lima, 2021).

Vale lembrar que a reconquista do território sagrado da Caiçara teve papel preponderante das mulheres Xokós, onde a comunidade entra num processo de resgate de sua identidade e das suas tradições, fortalecendo seus ritos sagrados que foram elos de sobrevivência de um povo que resistiu ao tempo e às pressões pelos processos de mudanças impostas externamente (FUNAI/ANAI, 2017).

Em 2021, o STF (Supremo Tribunal Federal) proferiu uma decisão importante ao reafirmar o "marco temporal", estabelecendo que os povos indígenas só têm direito às terras que estavam ocupando em 1988. Essa decisão gerou controvérsias e protestos por parte dos povos indígenas (Zechetto Neto& Amorim., 2022). em 21 de setembro de 2023 com o placar de nove a dois o STF julgou inconstitucional a tese do “Marco Temporal”.

Em 2017, através “Etnomapeamento da Terra Indígena Caiçara/ Ilha de São Pedro do Povo Xokó” a Funai (Fundação Nacional do Índio) e a Anai (Associação Nacional de Ação Indigenista) trouxeram à tona o exemplo notável do Território Indígena Caiçara e das comunidades circundantes na proteção eficaz de seus territórios e recursos naturais. Essas comunidades, com forte enraizamento em suas tradições culturais, têm demonstrado uma capacidade impressionante de gerir e preservar suas terras. Isso tem sido possível por meio de estratégias que envolvem a implementação de governança local, a formação de parcerias com organizações de conservação e, fundamentalmente, o reconhecimento de seus direitos territoriais.

O reconhecimento desses direitos não é apenas uma questão legal, mas um passo essencial para garantir que essas comunidades possam continuar a desempenhar seu papel

como guardiãs da natureza. Em um cenário global de crescentes desafios ambientais, a atuação dessas comunidades indígenas é um exemplo valioso de como o respeito aos direitos territoriais pode caminhar lado a lado com a preservação ambiental (Santos et al., 2022).

A colaboração entre comunidades indígenas, governos e organizações não governamentais é essencial para a conservação bem-sucedida. Essas parcerias podem criar estratégias eficazes de preservação ambiental pois, os territórios indígenas desempenham um papel vital na conservação e preservação ambiental, mas enfrentam desafios significativos. O reconhecimento de seus direitos territoriais e a promoção da colaboração são passos importantes para garantir um futuro sustentável para essas comunidades e para o meio ambiente em geral (Júnior, 2021).

### **2.3. Aplicação de SIG e Sensoriamento Remoto no Mapeamento das Fitofisionomias da Caatinga**

O Sistema de Informação Geográfica (SIG) e o sensoriamento remoto são tecnologias essenciais e complementares na análise de dados espaciais, embora possuam funções distintas. O “SIG” refere-se a um sistema computacional utilizado para o armazenamento, manipulação, análise e visualização de dados geográficos. Ele possibilita a execução de operações como sobreposição de camadas, recorte, união e análise espacial, permitindo que os usuários identifiquem áreas de interesse, calculem áreas e perímetros, e desenvolvam modelos preditivos (Longley et al., 2015). Dessa forma, o SIG é amplamente empregado para a geração de mapas temáticos e a análise de padrões espaciais, combinando dados vetoriais (como pontos, linhas e polígonos) e raster (imagens) em camadas interativas.

Por outro lado, o “sensoriamento remoto” refere-se à obtenção de dados da superfície terrestre sem a necessidade de contato direto, utilizando sensores a bordo de satélites, aeronaves ou drones. Esses sensores captam informações em diferentes faixas do espectro eletromagnético, como luz visível, infravermelho e micro-ondas, permitindo a detecção de características como tipos de cobertura do solo, variações de temperatura e umidade, entre outros aspectos ambientais (Teotia et al., 2009). As imagens capturadas por esses sensores são processadas e analisadas para identificar e classificar diferentes tipos de cobertura do solo, como florestas, áreas urbanas e agrícolas.

Embora o “sensoriamento remoto” seja responsável pela coleta de dados geoespaciais, o “SIG” atua como uma ferramenta de processamento, análise e visualização desses dados. A integração entre ambas as tecnologias é amplamente utilizada em estudos ambientais,

planejamento urbano, agricultura de precisão e monitoramento de recursos naturais. Por exemplo, dados obtidos via sensoriamento remoto podem ser processados no SIG para realizar a classificação da vegetação e, posteriormente, combinados com outras camadas de dados, como limites territoriais ou informações socioeconômicas, ampliando o potencial de análise e suporte à tomada de decisões (Campbell & Wynne, 2011).

O CBERS 04A desempenha um papel central no sensoriamento remoto do Brasil, sendo uma ferramenta indispensável para o monitoramento de recursos naturais, do uso do solo e do meio ambiente. Lançado em 2019, este satélite integra o programa de cooperação espacial entre Brasil e China, iniciado nos anos 1980, e marca um avanço importante na capacidade do país de monitorar seu território de forma autônoma. Equipado com sensores de alta resolução, o CBERS 04A fornece imagens detalhadas e multiespectrais, permitindo análises precisas sobre desmatamento, agricultura e mudanças ambientais (Martins& Pedro,2020).

O CBERS 04A é equipado com três câmeras de sensoriamento remoto, cada uma com funções específicas: a WPM (WidePanchromaticMultispectralCamera) oferece imagens pancromáticas de alta resolução (2 metros) e multiespectrais (8 metros), sendo ideal para o detalhamento de áreas urbanas e identificação de mudanças na superfície terrestre; a MUX (MultispectralCamera) capta imagens multiespectrais com resolução de 16 metros, sendo amplamente usada no monitoramento da vegetação, corpos d'água e uso do solo; e a IRS (InfraredCamera), com resolução de 40 metros, é especializada na captura de imagens no infravermelho termal, fundamental para a detecção de queimadas e análise de variações térmicas, como temperatura da superfície terrestre e estresse hídrico (Sollaci, 2023 Tabela 1).

Tabela 1: Principais características da Câmera WidePanchromaticMultispectral (WPM) do satélite CBERS 04A.

<b>Câmera Multiespectral e Pancromática de Ampla Varredura (WPM)</b>	
<b>Característica</b>	<b>Dado</b>
Bandas Espectrais	P (PAN): 0,45 - 0,90 $\mu\text{m}$ Banda 1(Blue): 0,45 - 0,52 $\mu\text{m}$ Banda 2(Green): 0,52 - 0,59 $\mu\text{m}$ Banda 3(Red): 0,63 - 0,69 $\mu\text{m}$ Banda 4(NIR): 0,77 - 0,89 $\mu\text{m}$
Largura da Faixa Imageada	92 km
Resolução Espacial	2 m (pancromática) 8 m (multiespectral)

Fonte: INPE (Adaptado), 2024

As imagens capturadas pelo CBERS 04A têm aplicações diretas no controle do desmatamento na Amazônia, na gestão de áreas de preservação e na análise de queimadas. O satélite permite que o Brasil acompanhe de perto as transformações no uso da terra, utilizando dados em tempo quase real para apoiar políticas públicas de conservação ambiental. Órgãos como o INPE utilizam essas informações para emitir alertas e realizar fiscalizações, ajudando a preservar a biodiversidade e os recursos naturais do país (Almeida, 2020).

Além do monitoramento ambiental, o CBERS 04A é utilizado na agricultura e na gestão de recursos hídricos, auxiliando no planejamento de culturas e na otimização do uso da água. As imagens multiespectrais fornecem dados valiosos sobre a saúde da vegetação, a umidade do solo e a distribuição de corpos d'água. Essa capacidade de sensoriamento remoto possibilita uma tomada de decisão mais precisa por parte de produtores rurais, governos e instituições de pesquisa (Silva, 2014).

O uso de algoritmos de aprendizado de máquina, como o Redes Neurais, o Random Forest e o Support Vector Machine (SVM), no processamento das imagens do CBERS 04A, amplia ainda mais sua importância. Esses algoritmos permitem a classificação precisa de diferentes tipos de uso do solo e cobertura vegetal, melhorando a acurácia das análises e possibilitando a detecção de padrões complexos. Ao combinar imagens de satélite com técnicas avançadas de análise de dados, o Brasil consegue desenvolver ferramentas mais eficazes para o monitoramento ambiental e a gestão sustentável de seus recursos naturais (Wolfer, 2020).

As Redes Neurais são um tipo de modelo de ALM inspirado no funcionamento do cérebro humano. Elas são compostas por camadas de neurônios interconectados, que são capazes de aprender e generalizar informações a partir de exemplos de treinamento (Raubert, 2005). No contexto da produção de mapas da Cobertura e do Uso da Terra, as Redes Neurais podem ser treinadas com dados de áreas já classificadas para aprender a identificar os padrões que caracterizam cada tipo de vegetação (de Oliveira Lima et al., 2023). Após o treinamento, as Redes Neurais podem ser utilizadas para classificar novos pontos no mapa, assim como o Random Forest e o SVM.

O Random Forest é um algoritmo de aprendizado de máquina que utiliza múltiplas árvores de decisão para classificar ou realizar regressões em conjuntos de dados (Breiman, 2001). Nesse contexto, ele pode ser aplicado para a classificação de diferentes tipos de cobertura vegetal em um determinado local, como florestas, pastagens, áreas urbanas, entre

outras (Sousa et al., 2023). O algoritmo analisa as variáveis ambientais, como a altura das árvores, a densidade da vegetação, a precipitação, entre outros, para identificar os padrões que indicam qual tipo de cobertura vegetal está presente em cada ponto do mapa.

O SVM é uma área da inteligência artificial que utiliza algoritmos para ensinar uma máquina a aprender padrões a partir de dados e fazer previsões ou tomar decisões (Andrade, 2021). Na produção de mapas de Cobertura e do Uso da Terra, o “SVM” pode ser utilizado para treinar um modelo com exemplos de diferentes áreas já classificadas, ou seja, ele aprende a reconhecer as características que determinam cada tipo de cobertura vegetal. Em seguida, o modelo pode ser usado para classificar novos pontos no mapa, identificando qual tipo de cobertura vegetal está presente em cada local (Leite, 2021).

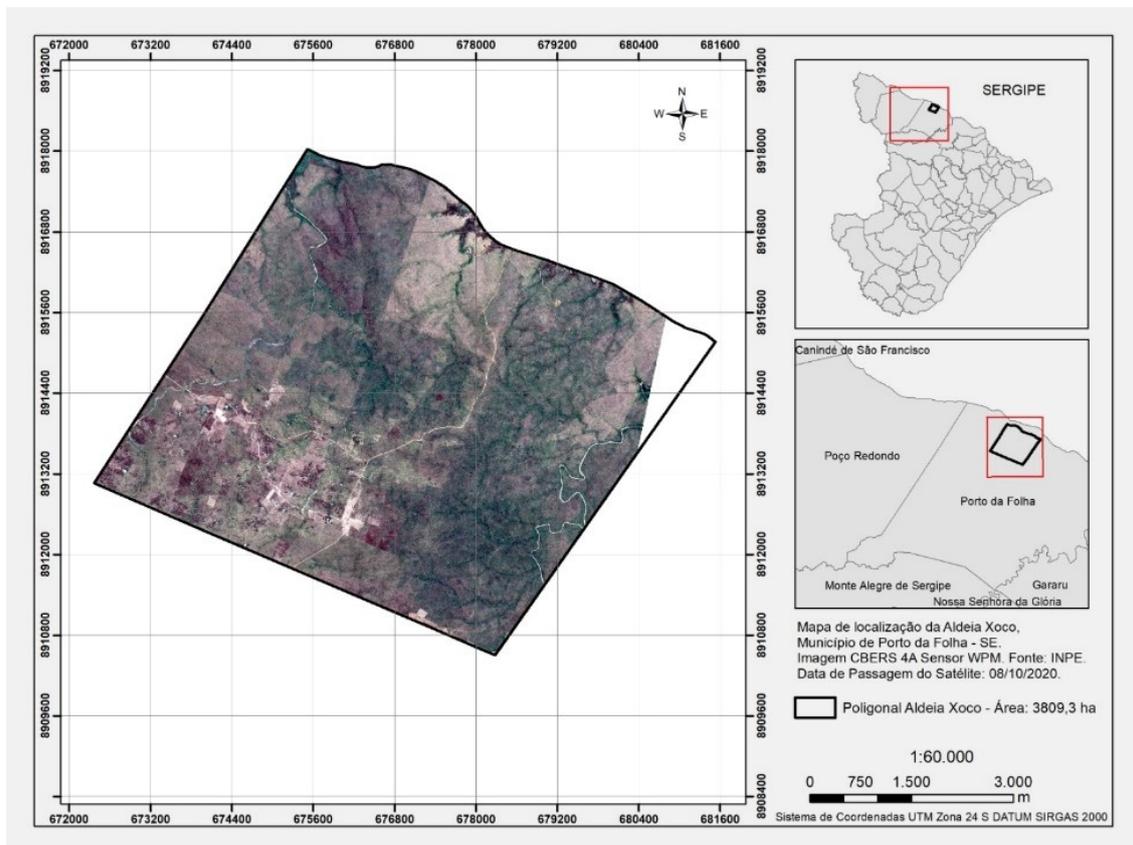
O uso de algoritmos, como as Redes Neurais, o Random Forest e o SVM na produção de mapas de Fitofisionomias da caatinga, permitem a análise das informações ambientais disponíveis para classificar diferentes tipos de vegetação em uma região específica (Venturieri et al., 1998). Essas ferramentas são capazes de aprender padrões a partir de exemplos de treinamento, permitindo a classificação automática de áreas desconhecidas e a produção de mapas precisos e atualizados.

### 3. MATERIAIS E METODOS

#### 3.1. Área de estudo

A Terra Indígena Caiçara/Ilha de São Pedro está situada na bacia hidrográfica do Rio São Francisco, no município de Porto da Folha, estado de Sergipe, ocupando uma área de 4.412,20 hectares, o que corresponde a 5% da extensão total do município (FUNAI, 2024. Figura 3).

Figura 3: Mapa de localização da Terra Indígena Caiçara/Ilha de São Pedro.



Fonte: Adaptado INPE, 2024

#### 3.2. Clima

O clima predominante é o Tropical Semiárido, caracterizado por uma estação seca bem definida e temperaturas elevadas durante todo o ano. A temperatura média anual é aproximadamente 26°C, com mínimas registradas em torno de 18,33°C no mês de agosto e máximas de até 35,36°C no mês de abril a precipitação anual na região foi de aproximadamente 446,40 mm entre outubro de 2022 e setembro de 2023. Durante esse período, os meses de novembro e dezembro foram os mais chuvosos relacionado as trovoadas,

enquanto abril e maio também apresentaram índices significativos de precipitação devido ao inverno na região. A umidade relativa do ar varia entre 50% e 70%, podendo cair para valores próximos a 30% durante os meses mais secos e subir para 80% nos meses chuvosos (INMET, 2024).

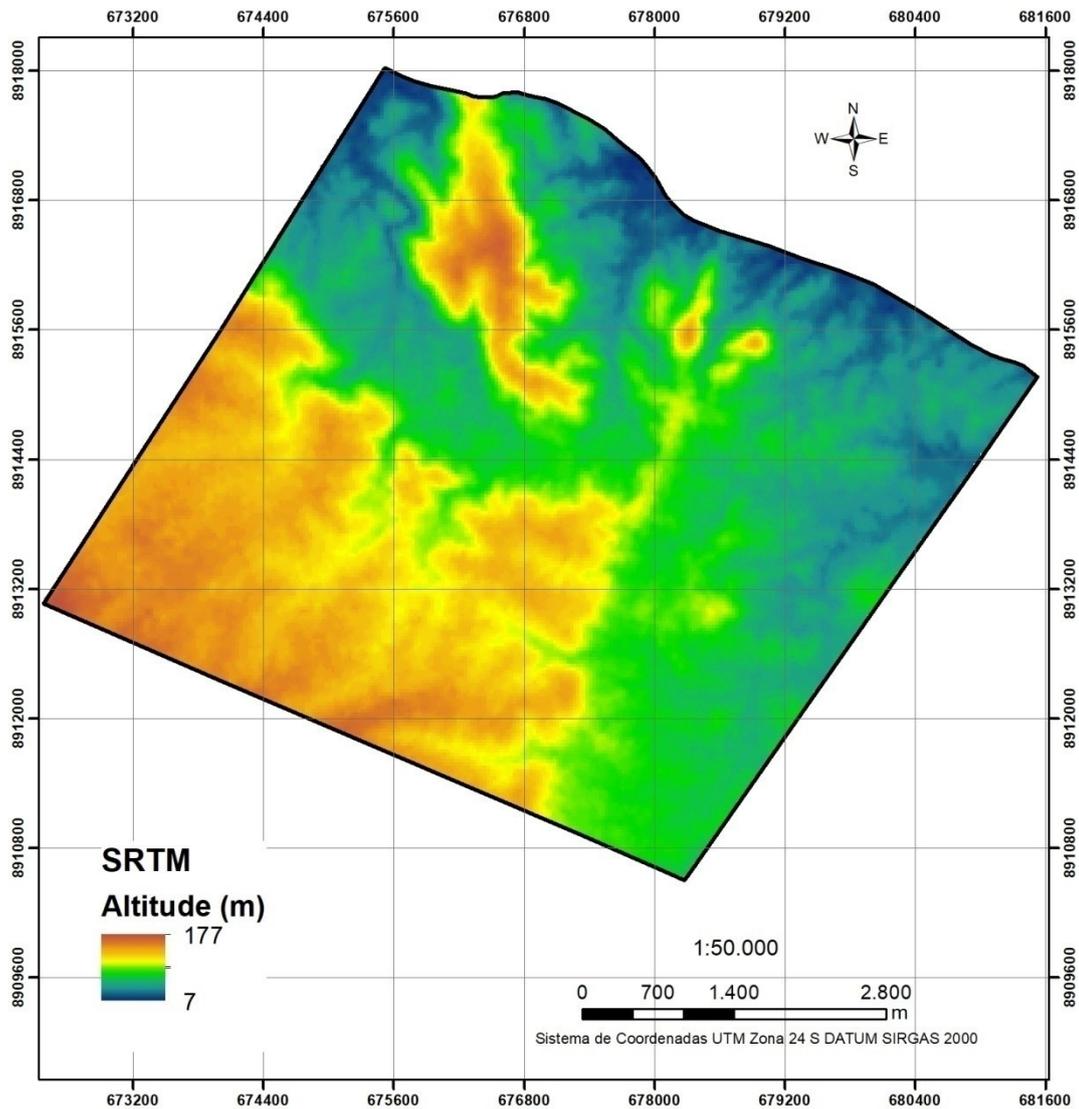
### 3.3. Vegetação

Em relação à vegetação, a Terra Indígena apresenta uma paisagem típica do bioma Caatinga, caracterizado por árvores e arbustos que se adaptam às condições de clima seco dentre elas se destacam em abundância, o juazeiro (*Ziziphus joazeiro*), a quixabeira (*Sideroxylon obtusifolium*) e a jurema preta (*Acacia jurema*). Nas serras predominam a catingueira (*Cenostigma pyramidale*) e o pereiro (*Aspidosperma pyrifolium*), mas também se encontram árvores como angico (*Anadenanthera colubrina*), umburana-de-cambão (*Commiphora leptophloeos*), umburana-de-cheiro (*Amburana cearenses*), braúna (*Melanoxylon braúna*), aroeira (*Myracrodruon urundeuana*) e barriguda (*Ceiba glaziovii*), além de outras espécies nativas como facheiro (*Pilosofereus pachycladus*) e mandacaru (*Cereus jamacaru*), sendo este último encontrado em abundância na região. Às margens do rio, na Caiçara e no Belém, há árvores como o mulungu (*Erythina verna*), jenipapo (*Genipa americana*), craibeira (*Tabebuia aurea*), marizeira (*Calliandra spinosa*), ingazeira (*Inga edulis*), goitizeiro (*Moquilea salzmännii*), araçá (*Eugenia stipitata*), entre outras (FUNAI/ANAI, 2017).

### 3.4. Relevo

Quanto ao relevo, a terra indígena está inserida em uma região de baixas altitudes variando de 7 a 177 metros acima do nível médio do mar (Figura 4).

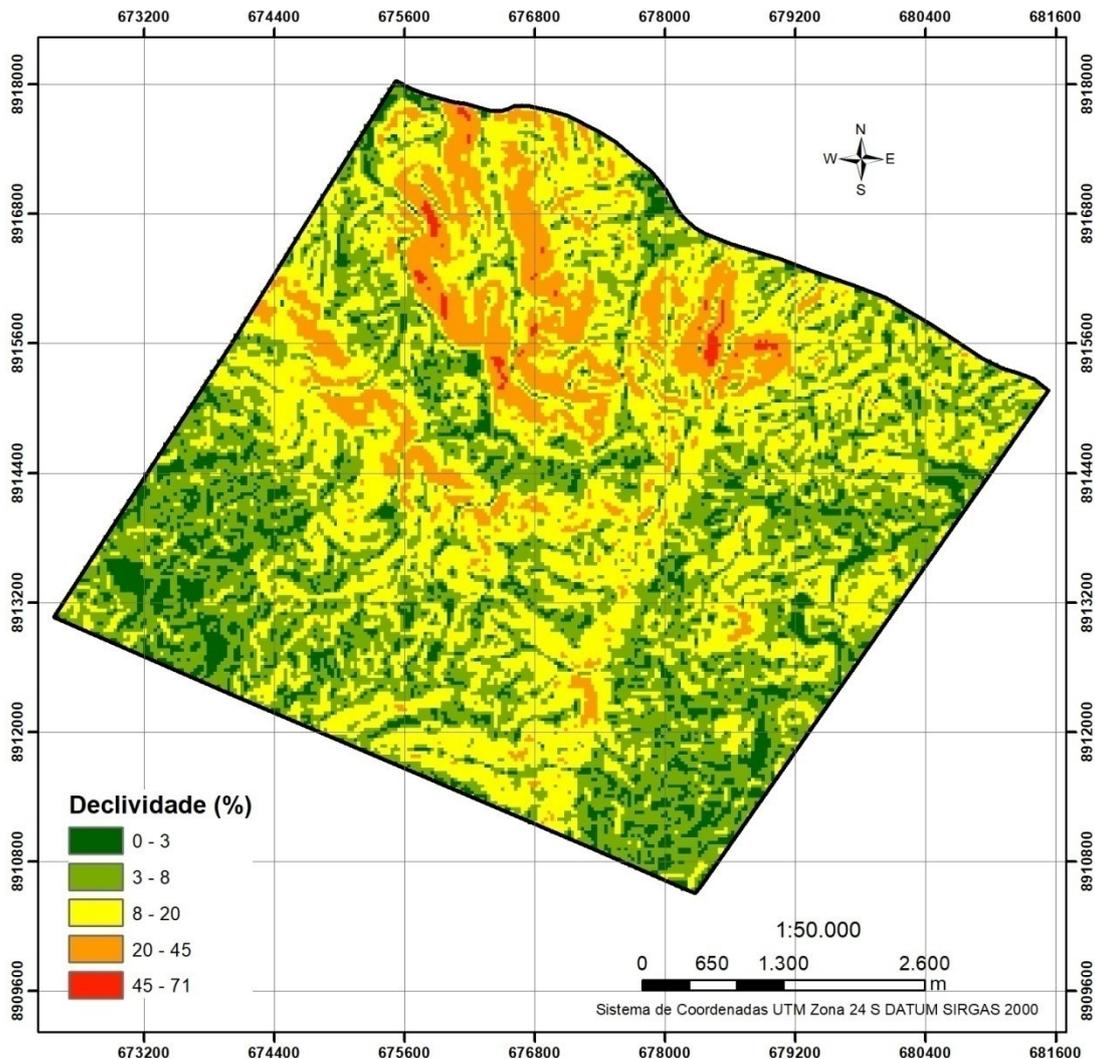
Figura 4: Imagem SRTM (Shuttle Radar Topography Mission) representando o Modelo Digital da Terra Indígena Caiçara/Ilha De São Pedro



Fonte: Adaptado NASA, 2024

Sua drenagem é caracterizada pelo escoamento das águas em direção ao Rio São Francisco, apresentando um relevo com declividades irregulares variando desde áreas planas até áreas mais declivosas, entre 45% e 71% de declividade (Figura 5).

Figura 5: Mapa de declividade da Terra Indígena Caiçara/Ilha de São Pedro.



### 3.5. Economia

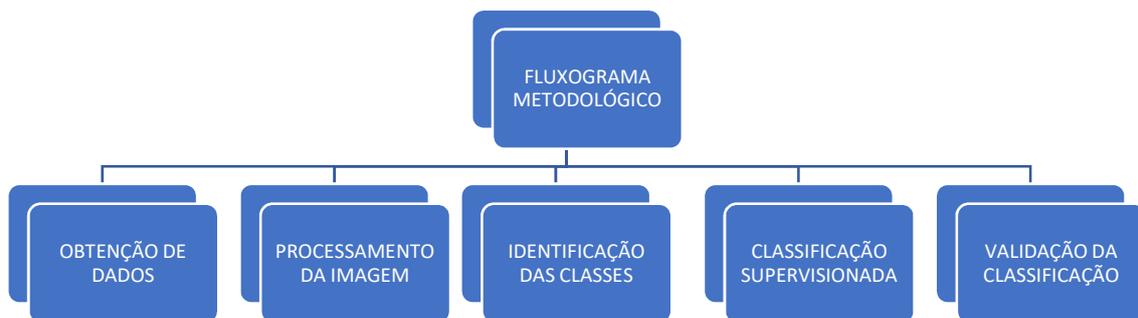
A população da terra indígena é de 340 habitantes (IBGE, 2024). As principais atividades econômicas dentro da Terra indígena incluem agricultura, criação de gado e pesca. As famílias garantem a segurança alimentar e geram excedentes para comercialização, alinhando a sua produção com as variações sazonais. Além disso, alguns membros da comunidade Xocó são funcionários de órgãos públicos relacionados à saúde e à educação. A comunidade Xocó também obtém recursos financeiros de vários programas sociais, como o Programa de Bolsa de Família e outros aposentados. A ocupação demográfica está situada ao

longo das margens do Rio São Francisco, juntamente com algumas áreas de atividades agrícolas sendo diretamente influenciadas pelo rio. Ao sul da Terra Indígena existe outra área de ocupação com um número limitado de famílias residentes o conhecido como “Marias Pretas” onde existem pastagens designadas para fins de criação de gado, tanto gado leiteiro como gado de corte. (FUNAI/ANAI, 2017).

### 3.6. Fluxograma metodológico

O fluxograma apresentado na “Figura 6” sintetiza todas as etapas realizadas neste trabalho, desde a obtenção dos dados, processamento da imagem, identificação das classes, classificação supervisionada, validação da classificação.

Figura 6: Fluxograma metodológico.



Fonte: Próprio autor, 2024

### 3.7. Obtenção de Dados

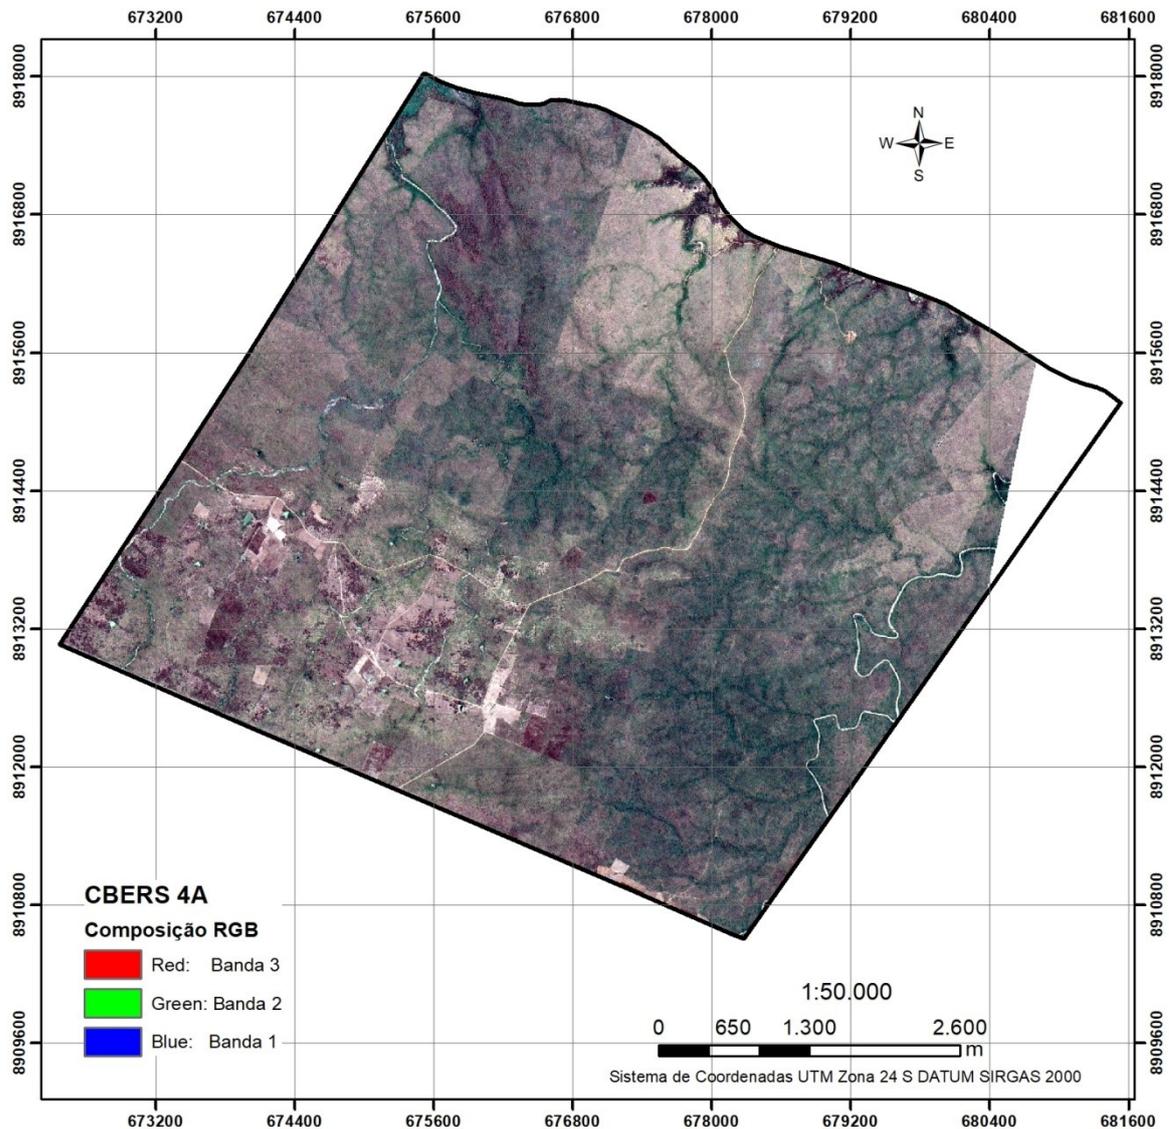
O mapeamento das fitofisionomias da Caatinga foi realizado com imagens de satélite e técnicas de sensoriamento remoto. Todos os dados de sensoriamento remoto utilizados foram reprojatados para o Datum Sirgas 2000 UTM Zona 24S.

Os limites da terra indígena foram retirados do banco de dados geoespaciais da Coordenação de Geoprocessamento da FUNAI (2024). Os dados estão disponíveis em diversos formatos, como Shapefile, KML, XLSX, CSV e ODS, permitindo a integração com diferentes sistemas.

Foram utilizadas composições de cinco bandas espectrais de imagens do satélite CBERS 04A Câmera WidePanchromaticMultispectral(<https://www.inpe.com/>) do ano de

2020. A câmera WPM é a principal carga útil do CBERS 04A. Seu objetivo é fornecer imagens com resolução panorâmica de 2m e resolução multiespectral de 8m simultaneamente na órbita do satélite (Figura 7).

Figura 7 - MAPA Terra Indígena Caiçara/Ilha de São Pedro CBERS 4A sensor WPM, data de passagem 08/10/2020.



Fonte: Adaptado INPE, 2024

Além dos dados de sensoriamento remoto descritos acima, foi utilizado o Modelo Digital de Elevação (MDE) derivado do Shuttle Radar Topography Mission (SRTM) para determinação da elevação (metros) e da declividade (%) do terreno da Terra Indígena Caiçara/Ilha de São Pedro.

Estes dados de radar estão disponíveis no site da Agência Espacial Americana (NASA) no endereço “<http://srtm.usgs.gov/data/obtainingdata.html>”. Estes dados possuem resolução

espacial de 90 m e escala equivalente à 1:250.000. Estas informações secundárias foram utilizadas apenas para realizar uma caracterização física da área.

### **3.8. Técnicas de Aprendizado de Máquina (métodos de classificação)**

Foram utilizados algoritmos de aprendizado de máquina (Machine Learning) que são apresentados em estudos de classificação supervisionada em diferentes regiões climáticas (Segal, 2004; Gleason; Im, 2012; Xi et al., 2020; Li et al., 2020; Pourghasemi et al., 2020). Os algoritmos testados incluíram Random Forest (RF), Redes Neurais Artificiais (RN) e Support Vector Machine (SVM).

O processo de classificação supervisionada das imagens do satélite CBERS 4A WPM foi conduzido e desenvolvido na linguagem de programação estatística e gráfica do software R (versão 3.6.2), utilizando-se de regressões não paramétricas e consonância (Hong et al., 2020).

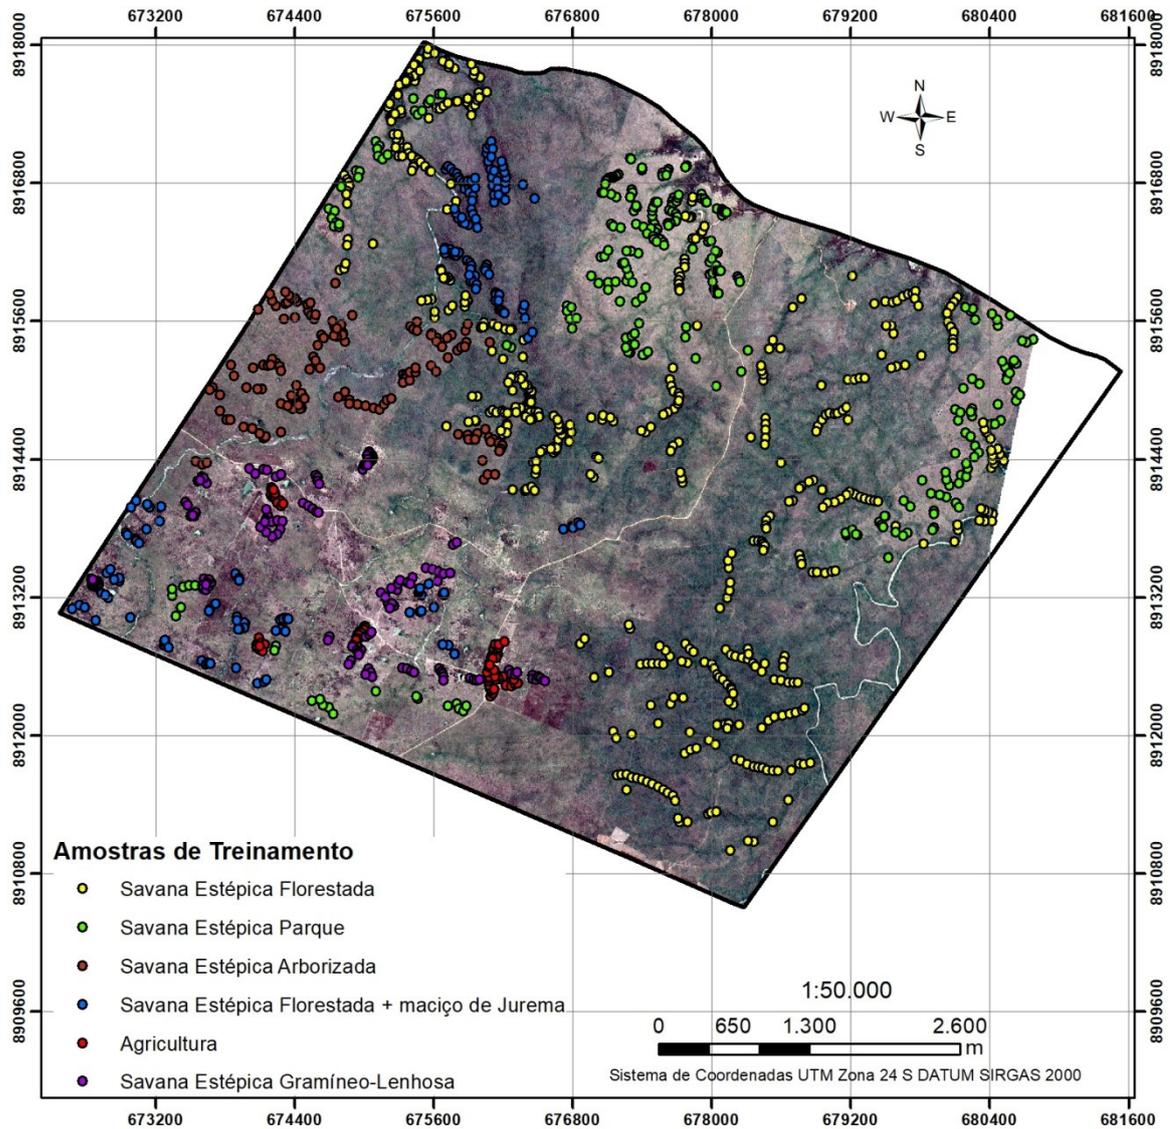
Para a obtenção dos dados, foram empregados os pacotes: (i) raster, que possui implementos básicos e funções de alto nível para manipulação de dados raster, como os dados Landsat (Hijmans, 2020); (ii) caret, sigla para treinamento de regressões e classificações, que converte funções e classes treinadas em matrizes de confusão, além de criar gráficos de classificação e modelos de regressão (Kuhn, 2020); (iii) rgdal, uma biblioteca que armazena dados geoespaciais (Bivand, 2020); (iv) RandomForest, baseado no método de florestas aleatórias de Breiman (2001) (Liaw, 2018); e (v) nnet, utilizado para redes neurais artificiais avançadas com uma única camada para modelos logísticos lineares multinomiais (Ripley; Venables, 2020).

Esses pacotes, como caret e raster, também foram úteis na espacialização das fitofisionomias da Caatinga, a partir dos modelos e equações aplicadas nos algoritmos RF, SVM e RN.

#### **3.8.1. Amostras de treinamento**

Foram selecionadas manualmente, a partir da imagem CBERS 04A, aproximadamente 1300 amostras pontuais de treinamento para cada fitofisionomia da caatinga pré-identificado visualmente na imagem e levantamento de campo (Figura 8). Na fase de treinamento do RF, 70% dos dados foram considerados e na fase de validação, 30 %.

Figura 8 - Distribuição espacial das amostras pontuais de treinamento para cada fitofisionomia da Caatinga.



Fonte: Próprio Autor

### 3.8.2. Random Forest (RF)

Foi utilizado o método de classificação supervisionada Random Forest (RF) (Breiman, 2001). O algoritmo RF foi executado no pacote caret do software R (Kuhn 2020) a partir do código implementado por Alba et al (2020).

### 3.8.3. Support Vector Machine (SVM)

No presente trabalho foi utilizado a função kernel RBF, que permite resolver problemas de separação não linear, projetando-os para um espaço de maior dimensão. Ao utilizar essa função, foi ajustado corretamente dois parâmetros: o gamma ( $\gamma$ ) e o fator de

penalidade (C) (Oliveira Junior, 2010). Foi utilizado o método one-against-one, que envolve a criação de diversos classificadores (Borges, 2003), resultando na construção de  $k(k-1)/2$  classificadores SVM, onde  $k$  é o número de classes (Lorena e Carvalho, 2007).

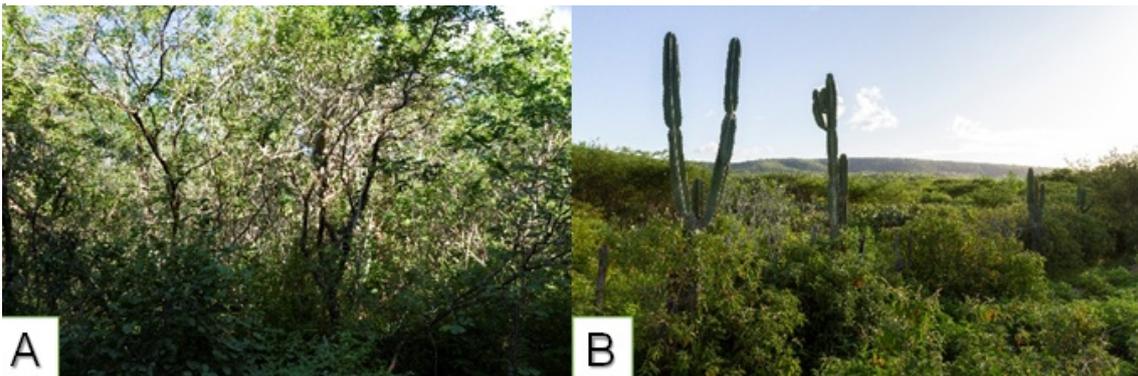
#### 3.8.4. Redes Neurais (RN)

A abordagem aqui descrita utiliza redes neurais para extrair conhecimento de um conjunto de dados previamente validado, composto por diferentes fitofisionomias da caatinga. Neste estudo, empregamos o pacote NNET (Venables, W. N. & Ripley, B. D. 2002) da linguagem R para implementar uma rede neural do tipo perceptron multicamadas, com uma camada oculta.

### 3.9. Classes Mapeadas

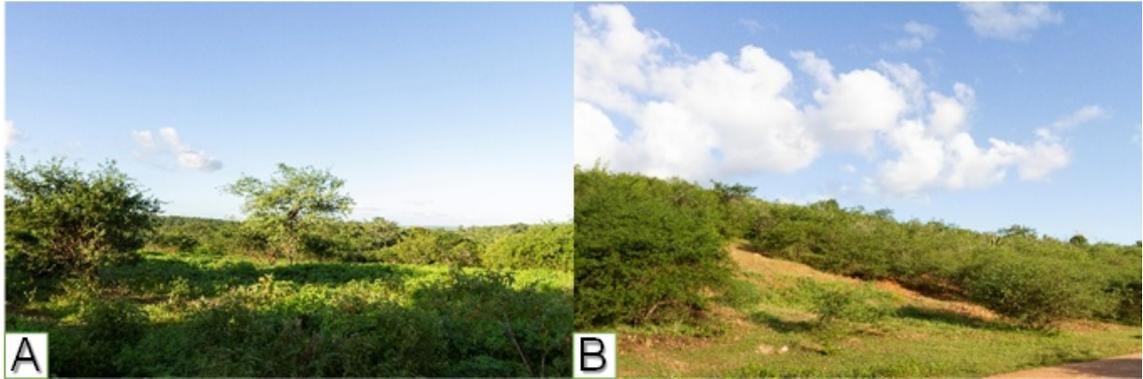
Foram consideradas para classificação das técnicas de aprendizado de máquina cinco fitofisionomias: Savana Estépica Florestada (Figura 9A), Savana Estépica Parque (Figura 9B), Savana Estépica Arborizada (Figura 10A), Savana Estépica Florestada + maciço de Jurema: área semelhante a Savana Estépica Florestada, mas com predominância da jurema apresentando característica de cor diferente (Figura 10B), Agricultura (Figura 11A); Savana Estépica Gramíneo-Lenhosa (Figura 11B). As classes de fitofisionomias da Caatinga foram definidas de acordo os critérios estabelecidos no Manual técnico da vegetação (IBGE, 2012).

Figura 9: Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Savana Estépica Florestada (A) e Savana Estépica Parque (B)



Fonte: Próprio autor, 2024

Figura 10 - Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Savana Estépica Arborizada (A) e Savana Estépica Florestada + Maciço De Jurema (B)



Fonte: Próprio autor, 2024

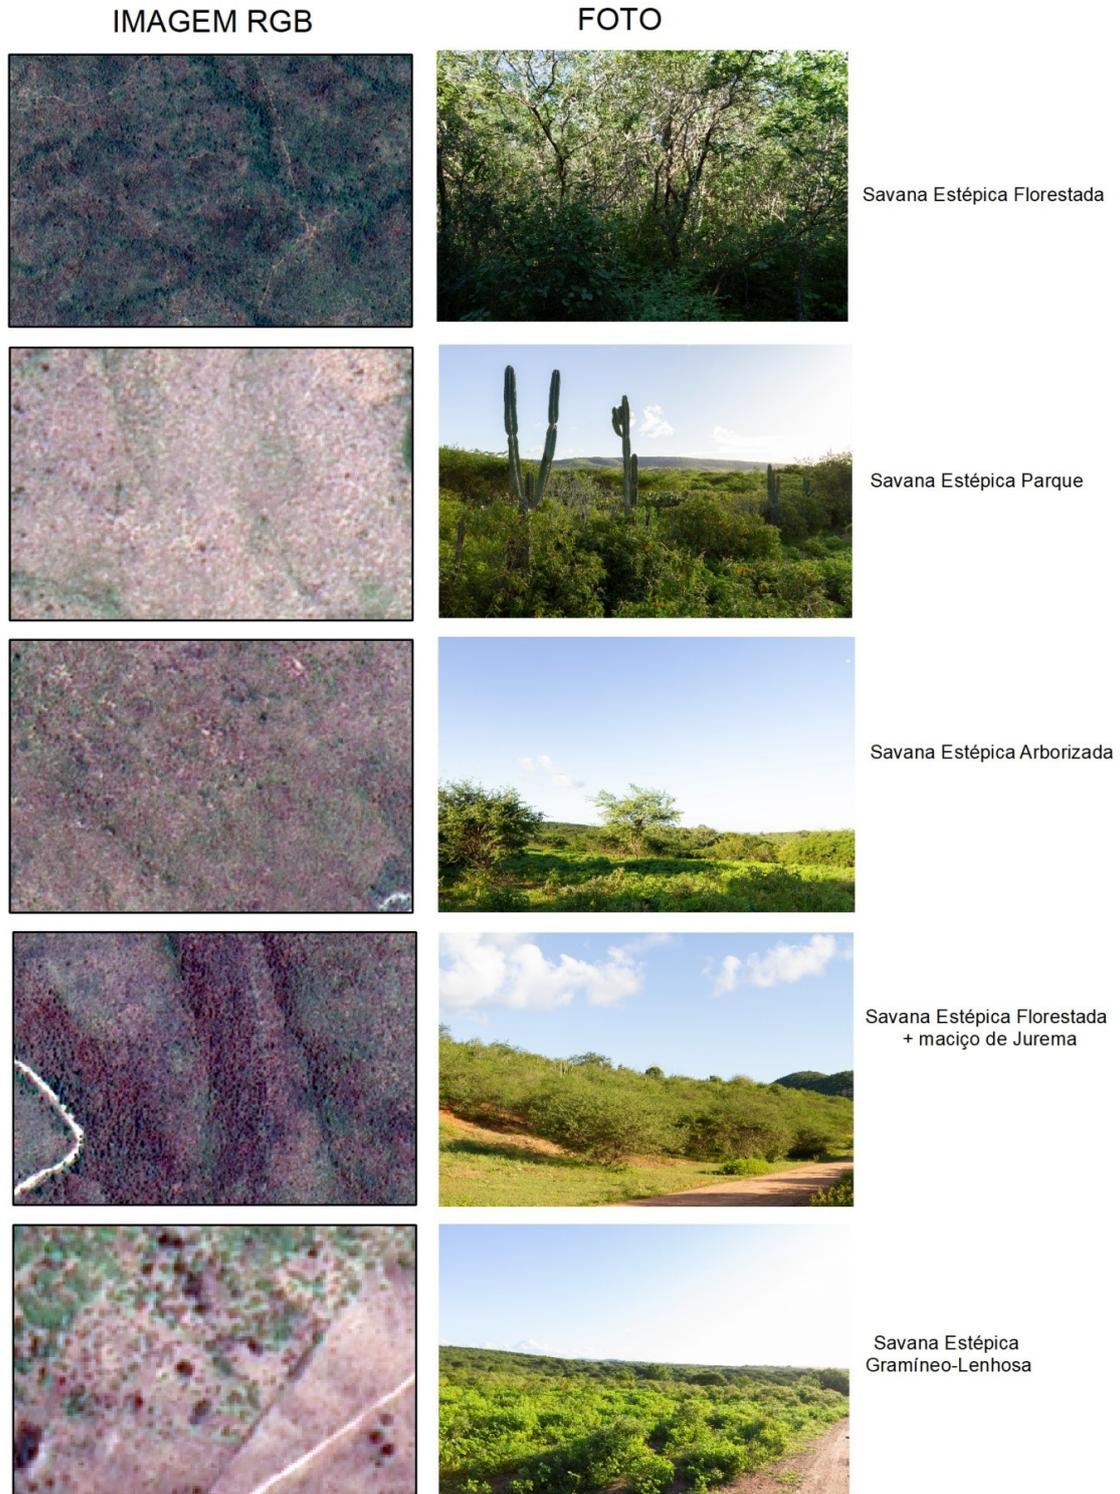
Figura 11 - Fotos da vegetação da Terra Indígena Caiçara/Ilha de São Pedro correspondente as classes Agricultura (A) E Savana Estépica Gramíneo-Lenhosa (B)



Fonte: Próprio autor, 2024

A Figura 12 mostra as diferentes fitofisionomias mapeadas na imagem CBERS 4A composição RGB e sua respectiva foto no campo.

Figura 12 - Diferentes fitofisionomias mapeadas na imagem CBERS 4A composição RGB e sua respectiva foto no campo.



Fonte: Próprio Autor

### 3.10. Software utilizados

Todas as informações espaciais descritas acima foram processadas no SIG livre Qgis (Development Team, 2020). A classificação das imagens e análises estatísticas descritas foram realizadas no software livre R (R Core Team, 2020).

### 3.11. Validação da classificação

A última etapa da classificação digital de imagens corresponde a avaliação da qualidade dos classificadores. A validação da classificação foi realizada a partir da matriz de confusão uma tabela que é utilizada para avaliar o desempenho de um modelo de classificação, através da comparação das previsões do modelo com os valores reais fornecendo uma visão detalhada de como o modelo está saindo, sendo fundamental para calcular as métricas de desempenho “Exatidão do usuário (Eu), Exatidão do Produtor (Ep), Acurácia (Exatidão Global), os Índices de Kappa e de Tau”.

A Exatidão do usuário e a Exatidão do Produtor são métricas importante utilizadas na validação de classificações supervisionada principalmente em estudos de sensoriamento remoto e analisa de imagens, pois elas ajudam a entender a precisão da classificação e a qualidade dos dados produzidos (Congalton et al, 1991).

A acurácia é uma métrica simples que mede a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões, ela determina o grau de exatidão quantificando o nível do erro entre o valor desejado e o valor real, ou seja, quanto maior a acurácia mais autêntico a classificação será.

A análise da qualidade dos classificadores foi determinada a partir do índice Kappa que é uma métrica de concordância que fornece uma ideia do quanto às observações se diferenciam daquelas esperadas, fruto do acaso, indicando-nos assim o quão legítimo são as interpretações.

Os valores do índice de Kappa variam de 0 a 1 (Tabela 1), sendo que, quanto mais próximo de 1 representa uma maior concordância entre os pontos de referência e as categorias classificadas (Congalton et al, 1991).

O índice de Tau é similar ao índice de Kappa foi utilizado para avaliar a concordância entre as previsões do modelo de classificação supervisionada e as classificações reais, sendo adequado para dados ordinais (Congalton et al, 1991).

Esse coeficiente mede a consistência entre os rankings, onde valores próximos a 1 indicam forte concordância, 0 indica ausência de correlação, e valores próximos a -1 indicam discordância. O Tau de Kendall permite uma avaliação robusta em cenários onde a ordem das classes é relevante(Souza, 2020).

#### **4. RESULTADOS E DISCUSSÃO**

A partir da análise da matriz de confusão, observou-se que a identificação das fitofisionomias por meio do algoritmo Redes Neurais (Tabela 2) englobou menor valor da exatidão do usuário na classificação da classe agricultura (53,8%), com muita mistura com as classes Savana Estépica Parque e Savana Estépica Gramíneo-Lenhosa. Tanto o algoritmo Randon Forest (Tabela 3) quanto o Support Vector Machines(Tabela 4) apresentaram menor valor de exatidão do produtor para a classe agricultura, com maior confusão com a Savana Estépica Parque e a Savana Estépica Gramíneo-Lenhosa.Provavelmente isso ocorre, pois estas áreas são formadas por vegetação de arbustos e pequenas árvores, geralmente da mesma espécie, e com uma distribuição bastante espaçada, e área ocupada por vegetação herbácea baixa, sendo distinta por um extenso tapete de gramíneas.

Tabela 2 - Matriz de confusão dos algoritmos Redes Neurais da classificação das fitofisionomias da Caatinga.

REDES NEURAIIS									
CLASSES	Savana Estépica Florestada	Savana Estépica Parque	Savana Estépica Arborizada	Savana Estépica Florestada + maciço de Jurema	Agricultura	Savana Estépica Gramíneo-Lenhosa	total	eu	ep
Savana Estépica Florestada	146						146	100%	100%
Savana Estépica Parque		65	6		2	10	83	78,3%	79,3%
Savana Estépica Arborizada		4	35	6		2	47	74,5%	81,3%
Savana Estépica Florestada + maciço de Jurema			1	48			49	97,9%	88,9%
Agricultura		11	1		21	6	39	53,8%	91,3%
Savana Estépica Gramíneo-Lenhosa		2				27	29	93,1%	60%
<b>total</b>	146	82	43	54	23	45	393		

\*eu: exatidão do usuário; ep: exatidão do produtor.

Fonte: Próprio autor, 2024

Tabela 3 - Matriz de confusão dos algoritmos Random Forest da classificação das fitofisionomias da Caatinga.

RANDOM FOREST									
CLASSES	Savana Estépica Florestada	Savana Estépica Parque	Savana Estépica Arborizada	Savana Estépica Florestada + maciço de Jurema	Agricultura	Savana Estépica Gramíneo-Lenhosa	total	eu	ep
Savana Estépica Florestada	146						146	100%	100%
Savana Estépica Parque		76	1		2	3	82	92,7%	92,7%
Savana Estépica Arborizada		1	41			1	43	95,3%	95,3%
Savana Estépica Florestada + maciço de Jurema				54			54	100%	100%
Agricultura					19		19	100%	82,6%
Savana Estépica Gramíneo-Lenhosa		5	1		2	41	49	83,7%	91,1%
<b>total</b>	146	82	43	54	23	45	393		

\*eu: exatidão do usuário; ep: exatidão do produtor.

Fonte: Próprio autor, 2024

Tabela 4 - Matriz de confusão do algoritmo support vector machine da classificação das fitofisionomias da Caatinga

SUPPORT VECTOR MACHINES									
CLASSES	Savana Estépica Florestada	Savana Estépica Parque	Savana Estépica Arborizada	Savana Estépica Florestada + maciço de Jurema	Agricultura	Savana Estépica Gramíneo-Lenhosa	total	eu	ep
Savana Estépica Florestada	146			1			147	99,3%	100%
Savana Estépica Parque		70	4		5	7	86	81,4%	85,4%
Savana Estépica Arborizada		1	37	3		2	43	86%	86%
Savana Estépica Florestada + maciço de Jurema				50		1	51	98%	92,6%
Agricultura		2			14	1	17	82,4%	60,8%
Savana Estépica Gramíneo-Lenhosa		9	2		4	34	49	69,4%	75,5%
<b>total</b>	146	82	43	54	23	45	393		

\*eu: exatidão do usuário; ep: exatidão do produtor.

Fonte: Próprio autor, 2024

Os resultados obtidos revelam que os três algoritmos de classificação supervisionada demonstraram uma acurácia superior a 80%, conforme a categorização de Congalton (1991). Os Índices de Kappa associados a tais resultados apontam para uma classificação excelente. Notavelmente, o algoritmo Random Forest (RF) se destacou, exibindo um desempenho superior na classificação das fitofisionomias da Caatinga no território Indígena Caiçara/Ilha de São Pedro, com uma acurácia de 0,9593, índice de Kappa de 0,9472 e Índice de Tau de 0,9511 (Tabela 5) e com as classes 1 (Savana Estépica Florestada) e 4 (Savana Estépica Florestada + maciço de Jurema) apresentando melhores desempenho em número de amostra corretamente classificada nas respectivas classes de acordo com a exatidão do usuário e a exatidão do produtor (TABELA 2).

Tabela 5- Resultados da Acurácia, Índice De Kappa e Índice De Tau de Acordo com os Classificadores.

<b>CLASSIFICADORES</b>	<b>ACURÁCIA</b>	<b>ÍNDICE DE <i>Kappa</i></b>	<b>ÍNDICE DE <i>Tau</i></b>
<b>RN</b>	0,8702	0,8322	0,8443
<b>RF</b>	0,9593	0,9472	0,9511
<b>SVM</b>	0,8931	0,8610	0,8718

Fonte: Próprio autor, 2024

O segundo melhor desempenho entre os algoritmos foi o Support Vector Machines (SVM), com uma acurácia de 0,8931, índice Kappa de 0,8610 e índice Tau de 0,8718. O algoritmo Redes Neurais (RN) que apresentou um desempenho inferior dentre os três algoritmos avaliados, sendo 0,8702; 0,8322 e 0,8443 para os índices de exatidão global, Kappa e Tau respectivamente (Tabela 3).

Apesar de todos os algoritmos testados apresentarem bons resultados, o algoritmo RF se difere significativamente dos demais, expressando resultados superiores quando aplicado à identificação de padrões espaciais na vegetação de Caatinga na terra indígena, apresentando uma melhor variação dos padrões espectrais da Cobertura e do Uso da Terra.

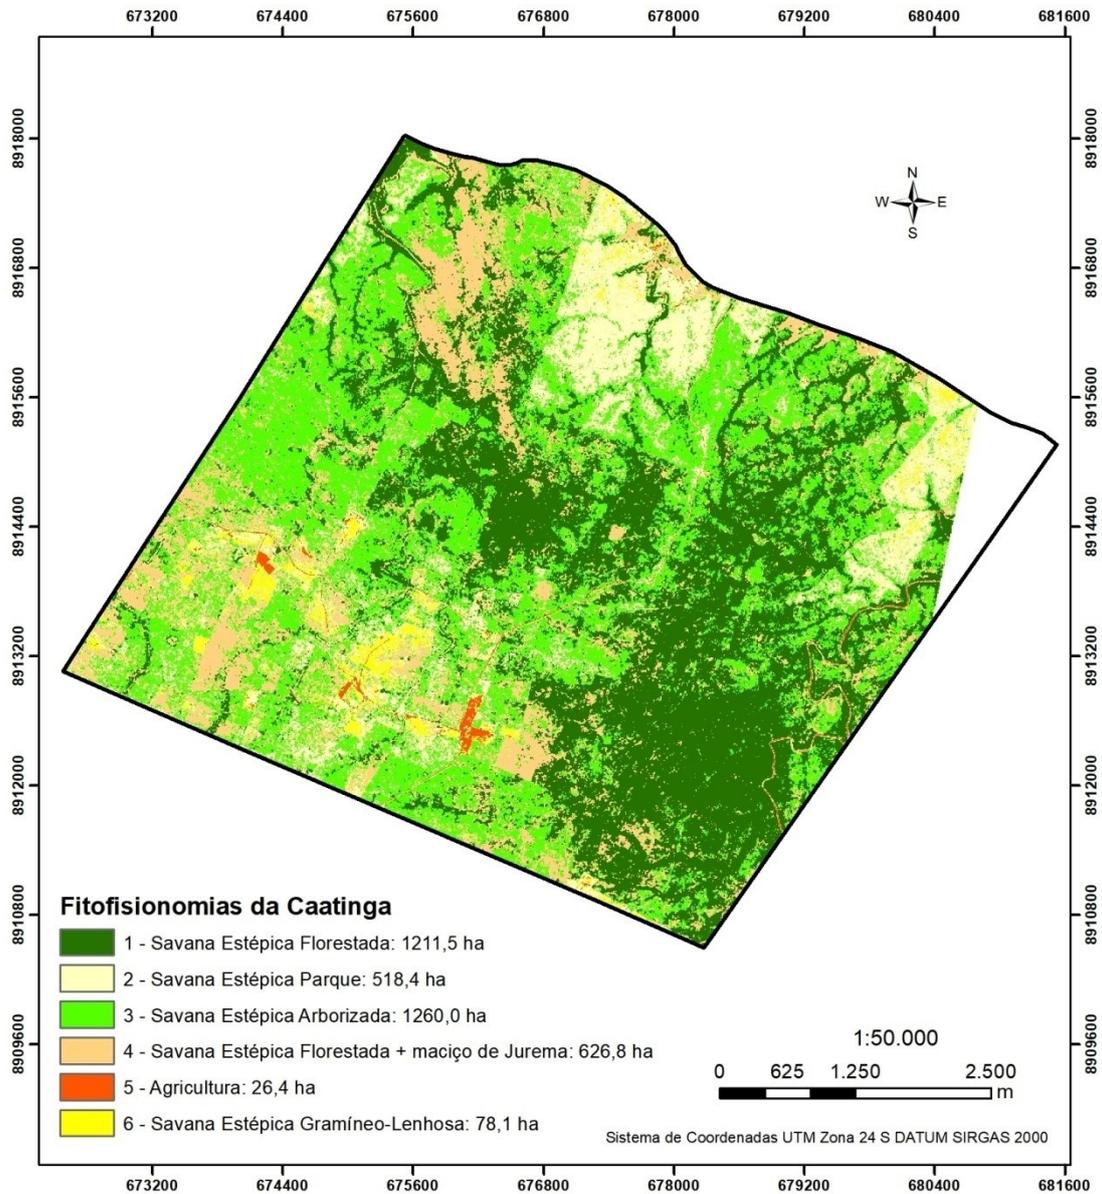
O algoritmo Random Forest tem se destacado em estudos de mapeamento de cobertura e uso da terra devido ao seu desempenho superior em comparação com outros métodos de classificação supervisionada. Por exemplo, Medeiro (2018) revisou diversas aplicações do Random Forest em sensoriamento remoto e destacou sua eficácia em fornecer classificações precisas e robustas devido à sua capacidade de lidar com grandes volumes de dados e variáveis correlacionadas. “da Cruz & Oliveira”. (2021) também compararam o Random

Forest com outros algoritmos e concluíram que ele oferece uma melhor precisão na classificação de cobertura e uso da terra urbana, o que é atribuído à sua resistência ao sobre ajuste e à sua habilidade de modelar relações complexas entre as variáveis de entrada. Além disso, Caon et al. (2019), demonstraram que o Random Forest supera outros métodos na classificação de imagens de satélite, sendo particularmente eficaz em cenários com dados ruidosos e heterogêneos. Esses estudos evidenciam a superioridade do Random Forest em contextos de mapeamento de cobertura e uso da terra, destacando sua robustez e precisão.

De forma similar ao que foi observado no estudo de Alba et al. (2022), onde o algoritmo Random Forest (RF) se destacou na identificação das fitofisionomias da Caatinga em Petrolina-PE utilizando imagens do satélite Landsat 8, o presente estudo também evidenciou a superioridade do RF. Com um desempenho superior aos demais algoritmos testados, como Support Vector Machine (SVM) e Redes Neurais, o RF apresentou acurácia mais elevada e maior índice Kappa. Isso demonstra a robustez desse algoritmo na classificação de áreas com vegetação sazonalmente seca, como a Caatinga, corroborando sua eficiência tanto em áreas urbanas quanto em territórios indígenas

A Figura 13 mostra o mapa com a quantificação da área pertencente aos tipos de classes de acordo com a fitofisionomia da caatinga obtido através do algoritmo Random Forest, separados em seis classes: 1211,5 ha de Savana Estépica Florestada; 518,4 ha de Savana Estépica Parque; 1260,0 ha de Savana Estépica Arborizada; 626,8 ha de Savana Estépica Florestada + maciço de Jurema; 26,4 ha de Agricultura; 78,4 ha de Savana Estépica Gramíneo-Lenhosa.

Figura 13: Mapa de Fitofisionomias gerado pelo classificador Random Forest na Terra Indígena Caiçara / Ilha de São Pedro.

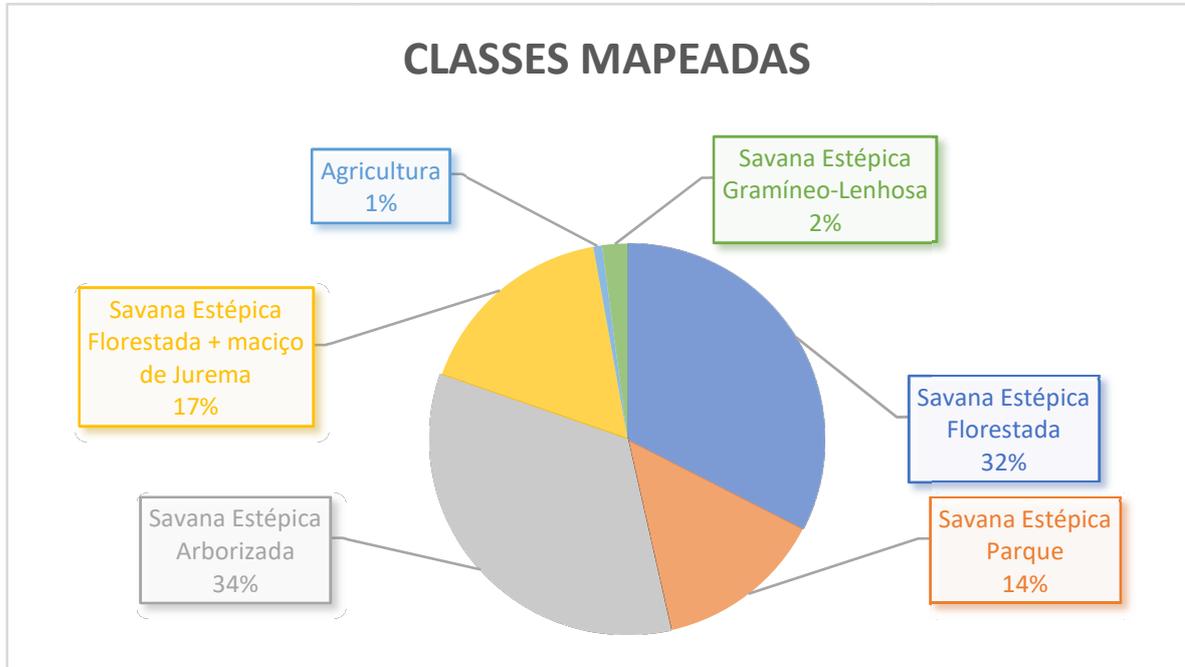


Fonte: Próprio autor, 2024

Na Figura 14 os resultados revelam que a maior parte da Terra Indígena Caiçara/Ilha de São Pedro é composta por áreas de Savana Estépica Arborizada (33,86%) e Savana Estépica Florestada (32,55%), totalizando mais de 66% do território sob vegetação nativa. A Savana Estépica Florestada + maciço de Jurema também é significativa, ocupando 16,84%. A comunidade indígena é fundamental na preservação dessas áreas, utilizando seu conhecimento ancestral para proteger ecossistemas essenciais. Com a agricultura ocupando apenas 0,71% da área, demonstram um manejo sustentável dos recursos naturais, garantindo a preservação da

biodiversidade e dos ciclos hídricos. Assim, a atuação da comunidade indígena é vital para equilibrar práticas tradicionais com a conservação ambiental, assegurando a sustentabilidade da região.

Figura 14 - Porcentagem de Fitofisionomias gerada pelo classificador Random Forest na Terra Indígena Caiçara / Ilha de São Pedro.



Fonte: Próprio autor, 2024

## 5. CONCLUSÃO

Este estudo revelou a superioridade do algoritmo Random Forest no mapeamento das fitofisionomias da Terra Indígena Caiçara/Ilha de São Pedro, destacando-o como o mais eficaz entre os métodos testados. Com uma acurácia superior a 95%, o Random Forest demonstrou sua capacidade de classificar com precisão as diferentes formações vegetais da Caatinga, superando os algoritmos Support Vector Machine e Redes Neurais. Essa eficiência, aliada ao manejo sustentável da comunidade indígena Xokó, reforça o papel vital das terras indígenas na preservação do bioma, evidenciando a importância da proteção dessas áreas para a conservação da biodiversidade e o equilíbrio ambiental no estado de Sergipe.

## 6. REFERÊNCIAS

- ALBA, Elisiane et al. Comparação entre algoritmos de aprendizado de máquina para a identificação de floresta tropical sazonalmente seca. *Anuário do Instituto de Geociências*, v. 45, p. 1-10, 2022.
- ALMEIDA, Dayse Silveira de. Análise do desmatamento e das queimadas na Amazônia Legal em 2018 e 2019 utilizando dados geoespaciais. *Boletim Campineiro de Geografia*, 2020.
- ANDRADE, João Maria de et al. Classificação da cobertura do solo da caatinga: avaliação de abordagens em Machine Learning utilizando dados Landsat Mono e multitemporais. 2021.
- BIVAND, R. RGDAL: Bindings for the Geospatial Data Abstraction Library. R package version 1.2-6. 2020.
- BORGES, J. S. Classificadores e Máquinas de Suporte Vectorial em Imagens Multi-Espectrais. 2003. 76 f. Dissertação (Mestrado) – Faculdade de Ciências, Universidade do Porto, Porto, 2003.
- BREIMAN, L. Random forest. *Mach Learn*, v. 45, n. 1, 2001.
- CAMPBELL, J. B.; WYNNE, R. H. *Introduction to remote sensing*. Guilford Press, 2011.
- CAON, Ivã Luis et al. Comparativo entre os classificadores RF e MAXVER, para classificação de uso e cobertura da terra, em diferentes densidades temporais. 2019.
- CONGALTON, R. G. A review of assessing the accuracy of classification of remotely sensed data. *Remote Sensing of Environment*, v. 37, p. 35-46, 1991.
- DA CRUZ, Elizeu Pinheiro. Biólogos e outros entes na caatinga: etnografia e endemismo em contextos de relações transespecíficas. *RELACult - Revista Latino-Americana de Estudos em Cultura e Sociedade*, v. 5, n. 1, 2019.
- DA CRUZ, Uilmer Rodrigues Xavier; DE OLIVEIRA, Luciel Passos. Comparativo entre os métodos de classificação MaxVer e Random Forest utilizando imagem Sentinel-2B. *Cadernos do Leste*, v. 21, n. 21, 2021.
- DANTAS, B. G. *Xokó: grupo indígena de Sergipe*. Aracaju: SEED/NEI, 1997.

DE JESUS, Janisson Batista et al. Fragmentação florestal em região semiárida no Nordeste do Brasil. *Pesquisa Florestal Brasileira*, v. 39, 2019.

DE OLIVEIRA LIMA, Felipe et al. Análise da dinâmica espacial da cobertura vegetal no oeste da Bahia por redes neurais. *Revista de Geografia - PPGeo-UFJF*, v. 13, n. 2, 2023.

FIORAVANTI, Carlos. Novo mapeamento expõe diversidade da Caatinga. *Pesquisa FAPESP Ambiente Biodiversidade Ecologia Geografia*, 2024.

FREIRE, Neison Cabral Ferreira et al. Mapeamento e análise espectro-temporal das unidades de conservação de proteção integral da administração federal no bioma Caatinga. *BrazilianJournalofDevelopment*, v. 6, n. 5, p. 24773-24781, 2020.

FUNAI. Terra Indígena Caiçara/Ilha de São Pedro. Disponível em:  
<https://www.gov.br/funai/pt-br/assuntos/terras-indigenas>. Acesso em: 27 ago. 2024.

FUNAI; ANAI. Etnomapeamento da Terra Indígena Caiçara/Ilha de São Pedro do Povo Xokó. Brasília/Salvador, 2017. 82 p.

GLEASON, C. J.; IM, J. Forest biomass estimation from airborne LiDAR data using machine learning approaches. *Remote Sensing of Environment*, v. 125, p. 80-91, 2012.

HIJMANS, R. J. Raster: Geographic data analysis and modeling. R package version 3.4-5.

HONG, D.; YOKOYA, N.; XIA, G. S.; CHANUSSOT, J.; ZHU, X. X. X-ModalNet: A semi-supervised deep cross-modal network for classification of remote sensing data. *ISPRS Journal of Photogrammetry and Remote Sensing*, v. 167, p. 12-23, 2020.

IBGE. População da Terra Indígena Caiçara/Ilha de São Pedro. Disponível em:  
<https://www.ibge.gov.br/cidades-e-estados/se/porto-da-folha.html>. Acesso em: 27 ago. 2024.

INMET. Dados Climáticos de Porto da Folha. Disponível em:  
<https://www.inmet.gov.br/portal/index.php?r=clima/index>. Acesso em: 27 ago. 2024.

INPE (Instituto Nacional de Pesquisas Espaciais). Programa CBERS. Brasília, DF: INPE, 2024. Disponível em: <https://www.gov.br/inpe/pt-br/programas/cbers>. Acesso em: 21 out. 2024.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA (IBGE). Manual técnico da vegetação brasileira. 2. ed. Rio de Janeiro: IBGE, 2012.

INSTITUTO NACIONAL DE METEOROLOGIA - INMET. Clima no Brasil: relatório anual 2020-2023. Brasília: INMET, 2024.

JÚNIOR, Francisco Gilson Rebouças Porto et al. Um olhar sobre a gestão ambiental dos povos indígenas na Amazônia Legal. *Revista Observatório*, v. 7, n. 1, p. a3pt-a3pt, 2021.

KUHN, M. CARET: Classification and Regression Training. R package version 6.0-86. 2020.

LARCHER, Walter. *Ecofisiologia vegetal*. 1977.

LEAL, Inara R. et al. Changing the course of biodiversity conservation in the Caatinga of northeastern Brazil. *Conservation Biology*, v. 19, n. 3, p. 701-706, 2005.

LEITE, Igor Vieira. Mapeamento dos remanescentes florestais da caatinga no estado de Sergipe usando imagens de satélite de alta resolução espacial e Machine Learning no Google Earth Engine. 2021.

LI, Y.; LI, M.; LI, C.; LIU, Z. Forest aboveground biomass estimation using Landsat 8 and Sentinel-1A data with machine learning algorithms. *Nature Scientific Reports*, v. 10, n. 1, p. 1-12, 2020.

LIAW, A. Breiman and Cutler's Random Forests for Classification and Regression. R package version 4.6-14. 2018.

LIMA, Yatan. O processo de esbulho da terra indígena Xokó da ilha de São Pedro/Caiçara, município de Porto da Folha, Sergipe: as consequências da Lei de Terras de 1850. *Revista Antígona*, v. 1, n. 2, p. 211-231, 2021.

LONGLEY, P. A. et al. *Geographic Information Systems and Science*. John Wiley & Sons, 2015.

LORENA, A. C.; CARVALHO, A. C. P. L. F. Uma introdução às Support Vector Machines. *Revista de Informática Teórica e Aplicada*, Santo André, v. 14, n. 2, p. 43-67, 2007.

- MARTINS, Patrick Thomaz de Aquino; PEDRO, Paulino Borges. Satélite sino-brasileiro de recursos terrestres na literatura científica global: tendências a partir de uma análise cienciométrica. *Boletim Goiano de Geografia*, v. 40, p. 1-25, 2020.
- MEDEIROS, L. F. de. *Inteligência artificial aplicada: uma abordagem introdutória*. Curitiba: InterSaberes, 2018.
- OLIVEIRA JUNIOR, G. M. Máquinas de Vetores Suporte: Estudo e Análise de Parâmetros para Otimização de Resultado. 2010. 41 f. Dissertação (Graduação) – Centro de Informática, Universidade Federal de Pernambuco, Pernambuco, 2010.
- OLIVEIRA, C. D. L. et al. Distribuição e importância das Unidades de Conservação no Domínio Caatinga. *Anuário do Instituto de Geociências*, v. 42, n. 1, p. 425-429, 2019.
- PEREIRA, C. L. et al. Contribuição dos biomas brasileiros para a redução da concentração de CO<sub>2</sub> na Amazônia, Mata Atlântica e Cerrado: uma revisão. *Biodiversidade Brasileira*, v. 10, n. 1, p. 61-76, 2020.
- PEREIRA, I. M.; ANDRADE, L. A. Restoration ecology of the Caatinga biome: Understanding the regional and seasonal context for ecological restoration. *Acta Botanica Brasilica*, v. 35, n. 2, p. 184-194, 2021.
- PINHOA, P. F. et al. Projeções de resiliência dos biomas brasileiros e riscos socioambientais às mudanças climáticas. *Sustainability in Debate*, v. 11, n. 3, p. 242-259, 2020.
- PINNA, R. Construindo aldeias e recuperando as florestas: conservação ambiental e a sustentabilidade Avá Guarani. *Anuário Antropológico*, v. 45, n. 1, 2020.
- POURGHASEMI, H. R.; GAYEN, A.; LASAPONARA, R.; TIEFENBACHER, J. P. Application of learning vector quantization and different machine learning techniques to assess forest fire influence factors and spatial modelling. *Environmental Research*, p. 109321, 2020.
- QGIS. Quantum GIS Development Team. QGIS Geographic Information System. Open Source Geospatial Foundation Project.
- R Core Team. R: A Language and Environment for Statistical Computing. R Foundation for Statistical Computing, Vienna, Austria, 2020.

RAUBER, T. W. *Redes neurais artificiais*. Universidade Federal do Espírito Santo, v. 29, 2005.

RIPLEY, B.; VENABLES, W. Feed-Forward Neural Networks and Multinomial Log-Linear Models. R package version 1.5-18. 2020.

RODAL, M. J. N. et al. Vegetação e flora da Caatinga. In: *Ecologia e conservação da Caatinga*. 2008.

SAMPAIO, E. V. S. B. Overview of the Brazilian Caatinga. In: *Seasonally dry tropical forests*. (Eds SH Bullock, HA Mooney, E Medina). p. 35–63, 1995.

SANTOS, B. K. J.; CARVALHO, G. B. V. Direito à terra dos povos indígenas no Brasil: entre insuficiências e potencialidades. *Revista Brasileira de Sociologia do Direito*, v. 9, n. 3, 2022.

SEGAL, M. R. Machine learning benchmarks and random forest regression. UCSF: Center For Bioinformatics and Molecular Biostatistics, 2004.

SILVA, J. M. C. et al. *Caatinga: The largest tropical dry forest region in South America*. Springer, 2017.

SILVA, M. P. et al. Degradação de bacias hidrográficas: análise do uso e cobertura da terra em uma bacia do nordeste paraense. *Revista de Ciências Ambientais*, v. 13, n. 1, p. 256-268, 2019.

SILVA, Samuel Ferreira da et al. Utilização do sensoriamento remoto na agricultura de precisão: uma análise bibliométrica. *Nucleus*, v. 11, p. 459-470, 2014.

SOLLACI, Catarina Balduino et al. Potencialidade dos dados WPM CBERS 4A para a identificação da interferência antrópica em elementos do ciclo hidrológico no campus Darcy Ribeiro da UnB. *Revista Brasileira de Geomática*, 2023.

SOUSA, J. H. S. et al. Aplicação do algoritmo Random Forest para classificação do uso e cobertura da terra na Bacia Hidrográfica do Rio Sucuru utilizando o Google Earth Engine. 2023.

SOUZA, L. B. et al. Erosão e uso do solo: uma revisão. *Revista Brasileira de Agropecuária Sustentável*, v. 8, n. 3, p. 48-59, 2018.

TEOTIA, H. S. et al. Integração do sensoriamento remoto e sistema de informações geográficas (SIG) para identificação, mapeamento e classificação do uso da terra e cobertura vegetal numa parte do Agreste Paraibano no Brasil. *XIV Simpósio Brasileiro de Sensoriamento Remoto*, Natal, p. 4489-4496, 2009.

UNIVERSIDADE DE BRASÍLIA. Odisseia: Bioma Caatinga. Brasília, DF: Universidade de Brasília, 2024. Disponível em: <https://odisseia.unb.br/sitios-de-pesquisa/bioma-caatinga/>. Acesso em: 15/10/2024.

VENABLES, W. N.; RIPLEY, B. D. *Modern Applied Statistics with S*. 4. ed. New York: Springer, 2002. ISBN 0-387-95457-0.

VENTURIERI, A.; SANTOS, J. R. Técnicas de classificação de imagens para análise de cobertura vegetal. 1998.

WOLFER, Matheus Frigo; MARCHESAN, Juliana et al. Análise do uso e cobertura da terra utilizando imagens Sentinel-2A e inteligência artificial. *Anuário do Instituto de Geociências*, 2020.

XI, Z.; HOPKINSON, C.; ROOD, S. B.; PEDDLE, D. R. Seetheforestandthetrees: Effective machine anddeep learning algorithms for woodfilteringandtreespeciesclassificationfromterrestrial laser scanning. *ISPRS JournalofPhotogrammetryand Remote Sensing*, v. 168, p. 1-16, 2020.

ZECHETTO-NETO, J. L. Z.; AMORIM, T. I. S. A inconstitucionalidade da tese do marco temporal para demarcação de terras indígenas. 2022