



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE DESENVOLVIMENTO SUSTENTÁVEL DO SEMIÁRIDO
UNIDADE ACADÊMICA DE TECNOLOGIA DO DESENVOLVIMENTO
CURSO DE BACHARELADO EM ENGENHARIA DE BIOSISTEMAS**

JOSÉ HUGO SIMPLICIO DE SOUSA

**APLICAÇÃO DO ALGORITMO RANDOM FOREST
PARA A CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA
NA BACIA HIDROGRÁFICA DO RIO SUCURU UTILIZANDO O
GOOGLE EARTH ENGINE**

**SUMÉ-PB
2023**

JOSÉ HUGO SIMPLICIO DE SOUSA

**APLICAÇÃO DO ALGORITMO RANDOM FOREST
PARA A CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA
NA BACIA HIDROGRÁFICA DO RIO SUCURU UTILIZANDO O
GOOGLE EARTH ENGINE**

Monografia apresentada ao Curso Superior de Engenharia de Biosistemas do Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Engenharia de Biosistemas.

Orientador: Professor Dr. George do Nascimento Ribeiro.

**SUMÉ - PB
2023**



S725a Sousa, José Hugo Simplicio de.
Aplicação do algoritmo Random Forest para
classificação do uso e cobertura da terra na Bacia
Hidrográfica do Rio Sucuru utilizando o Google Earth
Engine. / José Hugo Simplicio de Sousa. - 2023.

43f.

Orientador: Professor Dr. George do Nascimento
Ribeiro.

Monografia - Universidade Federal de Campina Grande;
Centro de Desenvolvimento Sustentável do Semiárido; Curso
de Bacharelado em Engenharia de Biosistemas.

1. Sensoriamento remoto. 2. Google Earth Engine. 3.
Algoritmo Random Forest. 4. Bacia Hidrográfica do Rio
Sucuru. 5. Classificação do uso e cobertura da terra. 6.
Caatinga. 7. Semiárido Paraibano. 8. Índices espectrais.
9. Classificadores espectrais. I. Ribeiro, George do
Nascimento. II. Título.

CDU: 528.8(043.1)

Elaboração da Ficha Catalográfica:

Johnny Rodrigues Barbosa
Bibliotecário-Documentalista
CRB-15/626

JOSÉ HUGO SIMPLICIO DE SOUSA

**APLICAÇÃO DO ALGORITMO RANDOM FOREST
PARA A CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA
NA BACIA HIDROGRÁFICA DO RIO SUCURU UTILIZANDO O
GOOGLE EARTH ENGINE**

Monografia apresentada ao Curso de Engenharia de Biosistemas do Centro de Desenvolvimento Sustentável do Semiárido da Universidade Federal de Campina Grande, como requisito parcial para obtenção do título de Bacharel em Engenharia de Biosistemas.

BANCA EXAMINADORA:

Prof. Dr. George do Nascimento Ribeiro
Orientador - UAEB/CDSA/UFCG

Prof. Dr. Paulo da Costa Medeiros
Examinador Externo I - UATEC/CDSA/UFCG

Prof. Dr. Paulo Roberto Megna Francisco
Examinador Externo I - CTRN/UFCG

Prof. Dr. João Miguel de Moraes Neto
Examinador Externo II - UAEA/CTRN/UFCG

Trabalho aprovado em: 04 de agosto de 2023.

SUMÉ - PB

AGRADECIMENTOS

À Deus, que me têm sustentado nas minhas fraquezas, necessidades e angustias.

A minha mãe Regilânia, que sempre teve ao meu lado, apoiando todas as minhas decisões para que eu pudesse me tornar cada vez mais forte, te amo mainha.

A meu padrasto João, que sempre buscou o melhor para mim, que ao longo desses anos me mostrou como ser um homem, te amo meu pai.

A meu irmão Jeferson, pelo incentivo e apoio, você foi essencial para o meu amadurecimento como pessoa.

A todos os meus professores de graduação em especial ao meu orientador de PIBIC e orientador do meu Trabalho de Conclusão de Curso, Dr. George do Nascimento Ribeiro, que acreditou no meu potencial e sempre esteve ao meu lado me orientando, pela confiança depositada e, principalmente, por sua paciência, para que eu conseguisse vencer mais esta etapa da minha vida.

Ao professor e amigo, Dr. Paulo Roberto Megna Francisco, por sua valiosa colaboração no meu crescimento acadêmico.

Ao professor e amigo, Msc. Wesley dos Santos Carvalho, por me orientar na estrutura e entender comandos de Java no script no Google Earth Engine.

Enfim, aos meus amigos da residência universitária do campus de Sumé e colegas que me ajudaram durante essa caminhada: Jarlean Lopes, Osmar Antônio, Pâmela Monique, Armando Henrique, José Ilton e Isaak Gerônimo.

“Talvez não tenha conseguido fazer o melhor, mas lutei para que o melhor fosse feito. Não sou o que deveria ser, mas Graças a Deus, não sou o que era antes”.

(Martin Luther King)

RESUMO

Através das ações antrópicas inadequadas ao longo dos anos na Bacia Hidrográfica do rio Sucuru, onde vem passando por mudanças no ecossistema. Mapas de uso e cobertura da terra são importantes ferramentas para fornecer informações precisas para monitoramento dinâmico, planejamento e gerenciamento de bacias hidrográficas. Com o advento das plataformas de computação em nuvem e classificadores de aprendizado de máquina, novas oportunidades estão surgindo para a classificação de uso e cobertura da terra mais preciso e mm larga escala. Objetivou-se obter uma classificação do uso e cobertura da terra na Bacia Hidrográfica do rio Sucuru, para o ano de 2022, através do classificador Random Forest, utilizando as bandas RGB e RGB combinada com índices espectrais (NDVI, NDWI, NDBI e SAVI), utilizando como parâmetros de precisão a Matriz de Confusão, Coeficiente Kappa, Acurácia Geral, Acurácia do Produtor e Acurácia do Usuário. A utilização da plataforma do Google Earth Engine para a elaboração e análise dos mapas de uso e cobertura da terra proporcionou resultados satisfatórios com rapidez e precisão. Observou-se que o melhor desempenho para o classificador Random Forest foi a combinação RGB-ÍNDICES, obtendo um bom desempenho na distinção das classes, como na classificação de uso e cobertura da terra, alcançando uma menor confusão espectral e uma acurácia acima de 89,98%, a adição de índices espectrais gerou níveis de precisão significativamente satisfatório.

Palavras-chave: Sensoriamento remoto, Semiárido, Caatinga, Sentinel-2.

SOUSA, José Hugo Simplicio de. **Application of the Random Forest algorithm for the classification of land use and land cover in the Sucuru River watershed using Google Earth Engine.** 2023. 43f. (Bachelor Thesis). Curso de Bacharelado em engenharia de Biosistemas, Centro de Desenvolvimento Sustentável do Semiárido, Universidade Federal de Campina Grande – Campus de Sumé – Paraíba – Brasil, UFCG. 2023.

ABSTRACT

Through the inadequate anthropogenic actions over the years in the Sucuru River Basin, where it has been undergoing changes in the ecosystem. Land use and land cover maps are important tools to provide accurate information for dynamic monitoring, planning and watershed management. With the advent of cloud computing platforms and machine learning classifiers, new opportunities are emerging for more accurate and large-scale land use and land cover classification. The objective was to obtain a classification of land use and land cover in the Sucuru River Basin, for the year 2022, through the Random Forest classifier, using the RGB and RGB bands combined with spectral indices (NDVI, NDWI, NDBI and SAVI), using as accuracy parameters the Confusion Matrix, Kappa Coefficient, General Accuracy, Producer Accuracy and User Accuracy. The use of the Google Earth Engine platform for the preparation and analysis of land use and land cover maps provided satisfactory results with speed and accuracy. It was observed that the best performance for the Random Forest classifier was the RGB-INDICES combination, obtaining a good performance in distinguishing the classes, as in the classification of land use and land cover, achieving a lower spectral confusion and an accuracy above 89.98%, the addition of spectral indices generated significantly satisfactory levels of accuracy.

Keywords: Remote Sensing, Semiarid, Caatinga; Sentinel-2.

LISTA DE MAPAS

Mapa 1 -	Localização da área de estudo.....	20
Mapa 2 -	Mapa hipsômetro da área de estudo.....	21
Mapa 3 -	Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB.....	27
Mapa 4 -	Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB-ÍNDICES.....	29

LISTA DE TABELAS

Tabela 1 - Matriz de confusão das bandas RGB do classificador RF.....	25
Tabela 2 - Matriz de confusão das bandas RGB-ÍNDICES do classificador RF.....	26
Tabela 3 - Resultados da classificação supervisionada do classificador RF pertencente a cada procedimento utilizado.....	28

LISTA DE ABREVIATURAS E SIGLAS

APIs	Application Programming Interfaces
BHRS	Bacia Hidrográfica do Rio Sucuru
CART	Classification and Regression Tree
FAO	Organização para Agricultura e Alimentação
GEE	Google Earth Engine
IBGE	Instituto Brasileiro de Geografia e Estatística
IA	Índice de Aridez
INPE	Instituto Nacional de Pesquisas Espaciais
LANDSAT	Land Remote Sensing Satellite
MODIS	Moderate Resolution Imaging Spectroradiometer
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
NDBI	Normalized Difference Building Index
NOAA	National Oceanic Atmospheric Administration
RF	Random Forest
RGB	Red – Green – Blue
SVM	Support Vector Machine
SAVI	Soil Adjusted Vegetation Index
SR	Sensoriamento Remoto
SCL	Scene Classification Map

SUMÁRIO

1	INTRODUÇÃO.....	11
2	OBJETIVO.....	13
2.1	OBJETIVO GERAL.....	13
2.2	OBJETIVOS ESPECÍFICOS.....	13
3	FUNDAMENTAÇÃO TEÓRICA.....	14
3.1	USO E COBERTURA DA TERRA.....	14
3.2	SENSORIAMENTO REMOTO (SR).....	15
3.2.1	Google earth engine (gee).....	16
3.3	CLASSIFICADORES ESPECTRAIS.....	16
3.3.1	Random forest (rf).....	17
3.3.2	Treinamento e avaliação da classificação.....	17
4	MATERIAL E MÉTODOS.....	20
4.1	CARACTERIZAÇÃO DA ÁREA DE ESTUDO.....	20
4.2	REMOÇÃO DE NUVENS E MOSAICO SENTINEL-2.....	22
4.3	TRANSFORMAÇÃO DE ÍNDICES ESPECTRAIS EM NOVAS BANDAS.....	22
4.4	COMPOSIÇÃO DOS CONJUNTOS DE DADOS USADOS PARA A CLASSIFICAÇÃO E COMPARAÇÃO.....	23
4.5	CONJUNTOS DE DADOS DE AMOSTRAS E CLASSES DE USO E COBERTURA DA TERRA.....	23
4.6	GERAÇÃO E VALIDAÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA.....	24
5	RESULTADOS E DISCUSSÃO.....	25
5.1	PRECISÃO DO RF COM AS COMBINAÇÕES DAS BANDAS.....	25
5.2	USO E COBERTURA DA TERRA NA BHRS.....	27
5.3	RF COM A COMBINAÇÃO RGB-ÍNDICES.....	28
6	CONCLUSÃO.....	32
	REFERÊNCIAS.....	33

1 INTRODUÇÃO

As atividades antrópicas desenvolvidas em áreas de bacias hidrográficas acarretam em uma série desdobramentos no meio ambiente (BARROS, 2021). Desde a ocupação da terra, uso indiscriminado da água, desmatamento de matas ciliares, sedimentação, assoreamento, construção de barragens, desvios de cursos d'água, erosão, salinização, contaminação, impermeabilização, compactação, diminuição da matéria orgânica dentre outras degradações, têm contribuído para o desaparecimento de rios e lagos, afetando profundamente o ciclo da água e o clima (ARAÚJO *et al.*, 2009).

Os estudos futuros serão mais fáceis de entender se compreendermos as formas de uso e cobertura da terra de várias escalas para vários fenômenos globais, como secas, inundações, erosão, migração e mudanças climáticas. A análise contínua e precisa de uso e cobertura da terra é parte integrante das atividades de desenvolvimento sustentável realizadas em determinadas áreas (ALDIANSYAH & SAPUTRA, 2023). Os mapas de uso e cobertura da terra tornam-se um componente importante para vários estudos científicos que envolvem os efeitos das mudanças climáticas nos fluxos e bacias hidrográficas dos rios (SRIDHAR *et al.*, 2019), geomorfologia (SUJATHA & SRIDHAR, 2018), gerenciamento de águas subterrâneas (XIAO *et al.*, 2022), conhecimento social para gestão de recursos naturais (SRIDHAR *et al.*, 2021) e monitoramento de terras agrícolas (JAMALI *et al.*, 2019).

A utilização do Sensoriamento Remoto (SR) e a aplicação conjunta de índices de vegetação, apresentam-se como instrumentos eficientes e eficazes para avaliar e monitorar as condições do uso e cobertura da terra vegetal de uma região geográfica, em função de sua precisão, praticidade e caráter multiespectral (CHAGAS, 2012; RIBEIRO *et al.*, 2016; SALLO *et al.*, 2014). O SR é o método mais comumente usado para mapear a cobertura da terra e rastrear suas mudanças ao longo do tempo (PHAN *et al.*, 2020).

As limitações na criação de mapas de cobertura da terra de baixa resolução em uma ampla área envolvem, é claro, grandes quantidades de dados. É necessária uma grande capacidade de armazenamento, poder de processamento e flexibilidade para implementar uma abordagem diversificada (XIE *et al.*, 2019).

Esse problema foi resolvido com a nova tecnologia Google Earth Engine (GEE). O GEE integra mais de 200 conjuntos de dados de SR, como LANDSAT, Sentinel e MODIS, e fornece ambientes de codificação *JavaScript* e *Python* para facilitar aos usuários o processamento de dados de acordo com suas próprias necessidades, realizando a operação de alto desempenho de dados de SR (FU *et al.*, 2021). O GEE pode ser utilizado por causa de seus amplos recursos em

vários campos de pesquisa baseados em uso e cobertura da terra. Midekisa *et al.* (2017), mostraram que o GEE foi capaz de produzir mapas multitemporais de uso e cobertura da terra no continente africano.

Kolli *et al.* (2020), demonstraram a capacidade do GEE em analisar a taxa de mudança no uso da terra ao redor do Lago Kolleru, na Índia, utilizando o algoritmo Random Forest e obtendo uma Acurácia Geral (A.G) de 95,9% com um Coeficiente Kappa (C.K) de 0,94%. Rahman *et al.* (2020), também analisaram o desempenho dos algoritmos RF e SVM para a área urbana de Bholá e a área rural de Dhaka, em Bangladesh, com uma precisão de 96,9 e 98,3%, respectivamente. Em geral, a GEE se concentra em análise de uso e cobertura da terra, monitoramento e gestão de recursos hídricos, de recursos agrícolas e no uso de índices de vegetação (SOUSA *et al.*, 2022; MAO & LI, 2023; LI *et al.*, 2021; BARBOSA *et al.*, 2021; WANG *et al.*, 2020; XIONG *et al.*, 2017; AIRES, 2018).

2 OBJETIVO

2.1 OBJETIVO GERAL

Classificar o uso e cobertura da terra na Bacia Hidrográfica do rio Sucuru (BHRS), Cariri Paraibano, para o ano de 2022, utilizando a plataforma do Google Earth Engine (GEE).

2.2 OBJETIVOS ESPECÍFICOS

- ✓ Testar a acurácia do algoritmo RF com a composição RGB;
- ✓ Testar a acurácia do algoritmo RF com a composição RGB combinada com Índices Espectrais (NDVI, NDWI, NDBI e SAVI);
 - ✓ Avaliar as mudanças entre as classes de cobertura e uso da terra;
- ✓ Avaliar a eficiência do algoritmo RF na plataforma GEE.

3 FUNDAMENTAÇÃO TEÓRICA

3.1 USO E COBERTURA DA TERRA

A cobertura da terra é definida como o estado biofísico apresentado na superfície e na subsuperfície próxima, a expressão da interação entre o ambiente físico, a biota, fatores climáticos e as intervenções antrópicas, enquanto o uso é a forma com que a terra está sendo aproveitado ou ocupado (CHU, 2020).

Nos últimos anos, as mudanças na cobertura da terra têm sido intensificadas em todo o mundo devido ao aumento populacional e à necessidade de abastecimento das cidades com água, alimento, fibras e abrigo. Tais mudanças são de grande importância pois influenciam no balanço energético, no clima, no balanço hídrico, nos ciclos biogeoquímicos e na provisão de serviços ecossistêmicos (CHU, 2020).

Para se definir um sistema em que se possa classificar o uso e cobertura da terra, bem como a realização de estudos de ecossistemas terrestres, permanece um desafio para o SR (YANG *et al.*, 2017). Existe uma diferença entre o uso e cobertura da terra, o uso da terra está ligado às interações humanas com as superfícies do mesmo, enquanto a cobertura da terra se refere às características da superfície da Terra (MARTINEZ & MOLLICONE, 2012).

Atualmente a plataforma do MapBiomas[®] possui um sistema de classificação hierárquico com uma combinação de classes uso e cobertura da terra compatível com os sistemas de classificação da Organização para Agricultura e Alimentação (FAO) (MACDICKEN, 2015) e IBGE (IBGE, 2009).

Para Aune-Lundberg e Strand (2014), o uso e cobertura da terra consiste nas relações características fundamentais do sistema terrestre intimamente conectado com as atividades humanas e o ambiente físico. Estas informações de uso e cobertura da terra são de fundamental importância para ecossistemas protegidos. A identificação e caracterização dos principais atributos desses recursos permitem aos gestores que monitorem a dinâmica da paisagem em grandes áreas, incluindo aquelas onde o acesso é difícil ou perigoso, e também facilita a extrapolação de medições de solo caras para monitoramento e gestão (LAMINE *et al.*, 2018). O mapeamento do uso e cobertura da terra usando imagens de satélite ou aerotransportadas permite a detecção de mudanças de curto ou longo prazo e o monitoramento de tais hábitos vulneráveis (SZANTOI *et al.*, 2015).

3.2 SENSORIAMENTO REMOTO (SR)

A popularização do uso do Sensoriamento Remoto (SR) nos estudos do meio ambiente, vem trazendo ótimos resultados no que tange os fenômenos ambientais, apresentando produtos atualizados dos mais diferentes biomas e regiões, através de instrumentos capazes de obter imagens da superfície terrestre e grandes distâncias, transformando os dados obtidos e registrados em informações úteis aos usuários finais dos produtos gerados por esta tecnologia, auxiliando no planejamento e gestão dos recursos naturais (SANTOS, 2018).

Segundo Florenzano (2002), o termo sensoriamento está associado à obtenção de dados por meio de sensores instalados em plataformas terrestres, aéreas (balões e aeronaves) e orbitais (satélites artificiais). O termo remoto, que significa distante, é utilizado porque a obtenção é feita à distância, ou seja, sem o contato físico entre o sensor e objetos na superfície terrestre. O processamento, a análise e interpretação desses dados também integram o SR.

Chang e Bai (2018), definem que o SR é um conjunto de técnicas que permitem a obtenção de informações das características de um alvo sem contato direto com o mesmo, a partir da captação da reflexão ou emissão deste alvo após a interação com alguma fonte de energia. Segundo Moraes Novo (2010), estudar fenômenos e processos que ocorrem na superfície terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias que a compõem, é o principal objetivo do SR.

O SR se apresenta como uma solução de baixo custo e grande aliado nas tomadas de decisões, quando comparado as medições realizadas *in loco*, porém, apresenta algumas desvantagens, como a necessidade de processamento para eliminar ruídos e a de validar as informações com visitas de campo (SAUSEN & LACRUZ, 2015).

Enfim, as áreas para aplicação do SR são muitas segundo Olorunfemi *et al.* (2017), o SR tem aplicações geográficas na agricultura, na geologia, na gestão de desastres, no planejamento, desenvolvimento e gestão urbana, na hidrologia, em estudos populacionais e planejamento de operações censitárias, na saúde humana e epidemiologia, arqueologia, climatologia, e monitoramento oceânico e costeiro. Barbosa *et al.* (2019), relatam que para agências governamentais, como o Instituto Nacional de Pesquisas Espaciais (INPE) o uso do monitoramento remoto é de grande relevância, pois utilizam, por exemplo, o monitoramento periódico dos corpos d'água e a gestão integrada de bacias hidrográficas que são indispensáveis para a conservação dos recursos hídricos.

3.2.1 Google earth engine (gee)

O Google Earth Engine (GEE) é uma plataforma de processamento geoespacial de grande volume de dados (*big data*) com base de dados em nuvem para monitoramento e análise ambiental em grande escala. É uma plataforma de uso gratuito, que fornece acesso a *petabytes* de imagens de sensoriamento remoto publicamente disponíveis e outros produtos para uso com um aplicativo da *web explorer*. Além disso, ela fornece o uso da infraestrutura do Google para processamento paralelo de alta velocidade e algoritmos de *machine learning* e acesso do ambiente de desenvolvimento que suportam linguagens de codificação *JavaScript* e *Python* da biblioteca de programação de interface de aplicação (*Application Programming Interfaces - APIs*). Esses recursos principais permitem que os usuários descubram, analisem e visualizem o *big data* geoespaciais sem a necessidade de acesso a supercomputadores ou conhecimento especializado em codificação (GORELICK *et al.*, 2017; TAMIMINIA *et al.*, 2020).

O catálogo de dados geoespaciais disponíveis no GEE é bastante vasto, sendo possível destacar produtos com cobertura regional e/ou global de diversos sensores como, ASTER e MODIS, além da coleção de imagens de satélites, LANDSAT, NOAA e Sentinel, assim como produtos MeaSURES (GANEM *et al.*, 2017).

Uma vantagem da plataforma é permitir ao usuário fazer desde simples análises estatísticas até operações mais complexas, como a geoestatística, tudo na própria nuvem do Google, o que facilita a extração de informações das imagens (GORELICK *et al.*, 2017). Além dos dados já disponíveis na infraestrutura Google, o usuário pode enviar os seus próprios dados produzidos para integrar o banco de dados da nuvem (GANEM, 2017).

3.3 CLASSIFICADORES ESPECTRAIS

Um dos usos mais conhecidos do SR é a classificação da cobertura e uso da terra. O classificador rotula todos os pixels de uma imagem de acordo com as características do comportamento espectral das amostras de treinamento de cada rótulo. As informações que podem ser extraídas da classificação são úteis na gestão de recursos ambientais, no monitoramento do uso da cobertura do solo, assim como no monitoramento de impactos que causam transformação do solo (KOTHARI & MEHER, 2020).

Em se tratando do bioma Caatinga, há especialmente duas dificuldades no mapeamento da distribuição espacial da cobertura da terra: a diversificação fitofisionômica da Caatinga e a inexistência de dados históricos para validação dos modelos de predição (LI *et al.*, 2017;

CASTANHO *et al.*, 2020; KOTHARI & MEHER, 2020). Uma alternativa para reduzir esta incerteza na classificação da cobertura da terra, é a aplicação de classificadores supervisionados baseados em dados obtidos em campo (COSTA *et al.*, 2018). Esses são frequentemente preferidos por analistas de áreas ambientais, praticantes da conservação e administradores de terras, devido à facilidade de uso (NIAZMARDI *et al.*, 2018).

Os classificadores supervisionados usam como referência dados discretos, previamente rotulados, para analisar e classificar dados contínuos por meio de algoritmos que calculam a similaridade ou discrepância entre o conjunto de dados (ZHANG, 2001; COSTA *et al.*, 2018). Apesar de mais trabalhosos, os estudos com classificadores supervisionados aumentaram bastante pois conferem bons resultados e alta precisão quando se tem um bom conjunto de dados (MA *et al.*, 2017).

Diversos algoritmos foram criados e amplamente difundidos, inclusive em análises ambientais, como Random Forest (RF), Support Vector Machine (SVM), Classification and Regression Tree (CART), e outros (WANG *et al.*, 2018; DEMIDOVA *et al.*, 2019; AMIRRUDDIN *et al.*, 2020).

3.3.1 Random forest (rf)

O RF é uma técnica de aprendizado de máquina desenvolvida por Breiman (2001), que possibilita a criação de modelos não lineares, utilizando grande número de variáveis independentes. Este algoritmo é baseado no conjunto de regras binárias para o particionamento de um conjunto de dados, este tipo de estrutura é chamado de árvore de decisão (FRATELLO & TAGLIAFERRI, 2018). RF é o mais usado para a classificação de imagens de uso e cobertura da terra e atualmente é utilizado por diversos autores (TAMIMINIA *et al.*, 2020; LIU *et al.*, 2020; FAGUA & RAMSEY, 2019; ALDIANSYAH & SAPUTRA, 2023). A técnica "*classifier.RandomForest*" da biblioteca GEE é usada neste estudo para realizar a classificação do uso e cobertura da terra com o algoritmo RF.

3.3.2 Treinamento e avaliação da classificação

O treinamento é uma parte determinante da classificação, uma vez que, o êxito do aprendizado de máquina está fortemente associado ao processo de treinamento e teste. As amostras de treinamento são agrupadas por rótulo de acordo com as características fitofisionômicas relevantes compartilhadas, enquanto o classificador analisa as características

da assinatura espectral dos alvos (AIAZZI *et al.*, 2012).

Assim, a diferenciação das classes pode ser melhor executada se os dados de treinamento permitirem mais facilmente a caracterização dos alvos. Uma amostra corresponde à coordenada geográfica em que a cobertura representa de forma relativamente homogênea a fitofisionomia desejada, e possui extensão suficiente para corresponder a um pixel satelital. A partir dos dados de posicionamento geoespacial podem ser fornecidos ao classificador atributos como valor das bandas, elevação, tipo de solo, índices de vegetação, de acordo com o tipo de classificação e a disponibilidade dos dados (AIAZZI *et al.*, 2012).

O tamanho do banco de amostras, assim como a divisão das amostras de treinamentos e de testes, varia de acordo com a área a ser estudada (YU *et al.*, 2006). Em regiões semiáridas, onde a classificação da cobertura do solo é particularmente difícil, devido à forte interferência do solo no período seco e, muitas vezes, pela falta de recursos para custear a coleta de dados *in situ*, a coleta de amostras tem sido limitada e a proporção entre o treinamento e o teste prioriza o treinamento do classificador (MARTÍNEZ-LÓPEZ *et al.*, 2014).

Segundo Santana (2021), o conjunto de amostras é dividido aleatoriamente. A divisão em dados de treinamento e teste varia bastante na literatura, no entanto, boa parte utiliza 70% no treinamento e 30% no teste (GE *et al.*, 2020; GANEM, 2017; ONOJEGHUO *et al.*, 2018; TSAI *et al.*, 2018; OLIVEIRA, 2021; SANTANA, 2021).

Para fornecer confiabilidade à classificação, foram desenvolvidos algoritmos que estimam o erro da previsão para avaliar a classificação. Os métodos de avaliação, em geral, utilizam amostras previamente rotuladas para calcular o erro da previsão do classificador (STEHMAN & FOODY, 2019). É recomendado que as amostras de teste sejam totalmente independentes das amostras de treinamento (LYONS *et al.*, 2018).

Das diversas maneiras de avaliar a precisão de um classificador, várias passam pela construção da matriz de confusão (FOODY, 2020). A matriz de confusão é um dos procedimentos mais comuns na avaliação de classificadores, uma vez que permite a visualização e a análise do desempenho da classificação das categorias individuais, bem como a precisão geral e de forma simples (CONGALTON *et al.*, 1983; LYONS *et al.*, 2018).

A matriz de erro ou matriz de confusão é uma das metodologias mais utilizadas para quantificar a acurácia de classificadores de imagens e tem sido amplamente utilizada por diversos autores (ANDRADE *et al.*, 2021a). A matriz de confusão é construída com base na comparação da classificação realizada e os dados de referência ou dados de teste (STEHMAN, 1997).

É possível quantificar as previsões errôneas das amostras testadas. Ao efetuar a razão

das amostras corretamente classificadas e o número total de amostras, obtém-se a precisão geral e pode-se calcular a porcentagem de acertos e erros por classe (LYONS *et al.*, 2018). A partir da matriz de erro ou matriz de confusão são derivados diversos índices, como o Coeficiente Kappa (C.K), Acurácia Geral (A.G), Acurácia do Produtor (A.P) e Acurácia do Usuário (A.U).

O C.K é utilizado para quantificação de quanto o modelo está bom, sendo uma técnica multivariada discreta que qualifica o nível de precisão assumindo valores na faixa de 0 a 1 (sendo que quanto mais próximo de 1, melhor é o resultado do classificador) (MONTEIRO, 2015).

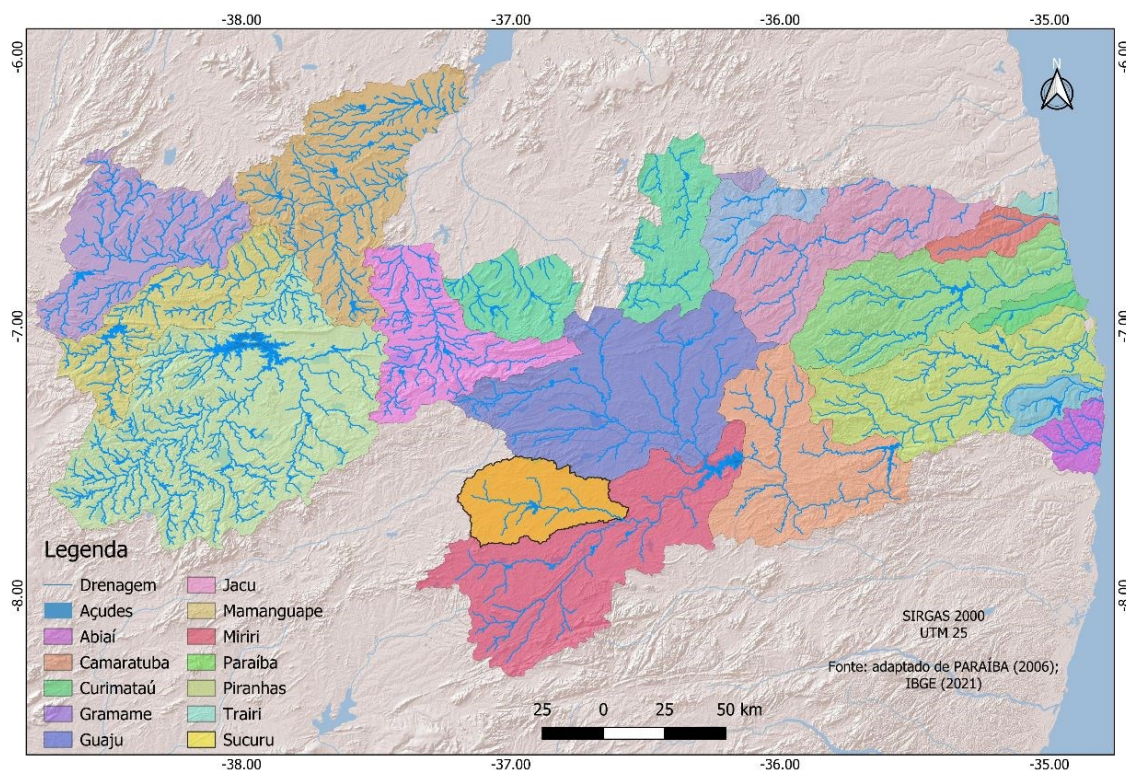
A A.G representa a probabilidade de uma amostra ser corretamente classificada (ESTRABIS *et al.*, 2019). A A.P está associada aos erros de exclusão, ou seja, pixels que deixaram de ser mapeados. A A.U está associada ao erro de omissão, ou seja, pixels classificados incorretamente (CAVALCANTE & LIMA, 2019).

4 MATERIAL E MÉTODOS

4.1 CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A Bacia Hidrográfica do rio Sucuru (BHRS) representa parcela significativa da bacia do Alto rio Paraíba e está localizada no semiárido paraibano (Mapa 1), na Mesorregião da Borborema e na Microrregião Homogênea do Cariri Ocidental, com área territorial de aproximadamente 1.652,5 km²; engloba total ou parcialmente os municípios de Amparo, Monteiro, Ouro Velho, Prata, Sumé, Serra Branca e Coxixola. A área se encontra entre as coordenadas geográficas 7°28'00" e 7°50'00" de latitude sul e 37°14'00" e 36°49'00" de longitude oeste (SANTOS *et al.*, 2020). A sua área de compreensão está totalmente inserida no Semiárido do Brasil, nos domínios da Caatinga com inúmeras variações paisagísticas (SILVA, 2017).

Mapa 1 - Localização da área de estudo



Fonte: Adaptado de PARAÍBA (2006); IBGE (2021); ESRI (2022).

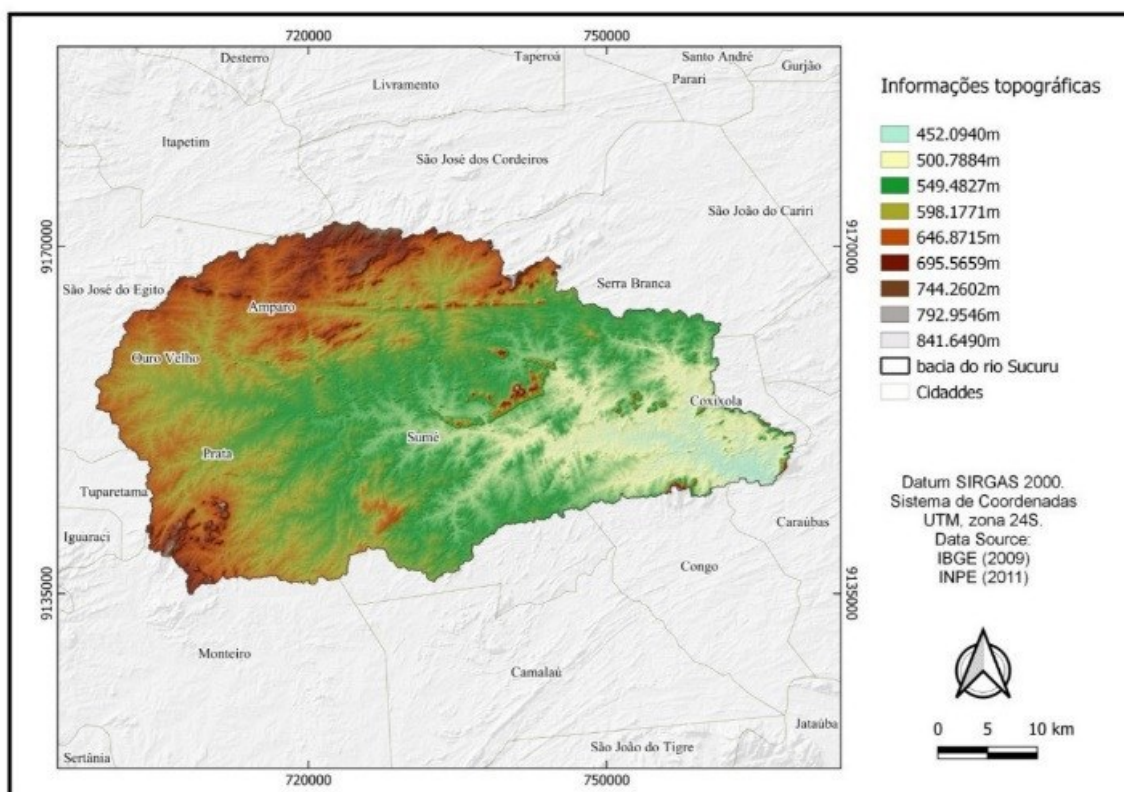
De acordo com a classificação de Gaussen a área em estudo está sob a influência dos tipos climáticos 4aTh (tropical quente de seca acentuada), 2b (subdesértico quente de tendência tropical) e 3aTh (mediterrâneo quente ou nordestino de seca acentuada). Não obstante, de

acordo com a classificação de Köppen, o clima predominante na região é do tipo Bsh (semiárido quente), com precipitações médias anuais baixas (em torno de 400mm) com estação seca que pode atingir até 11 meses. O índice de aridez (IA) de Thornthwaite para a bacia do Sucuru é de 0,22, que caracteriza o seu clima como semiárido (ALENCAR, 2008).

Diniz *et al.* (2020), ao realizarem pesquisa sobre o índice de anomalia de chuvas na microrregião do Cariri Ocidental em um período de 21 anos (1999-2019), obtiveram como resultado que, a climatologia temporal da precipitação na região de estudo, compreende como o período chuvoso entre os meses de janeiro a maio, em contrapartida o período seco ocorre entre os meses de junho a dezembro, sendo setembro tido como o mês mais seco.

Com relação aos aspectos físicos da BHRS, observa-se no Mapa 2 que, em geral, predominam altitudes entre 452 a 841 m. Especificamente, nas regiões sul, oeste e norte, o relevo é irregular e não homogêneo, compreendendo ao Planalto da Borborema, caracterizada por altas elevações. Em contrapartida, o Leste possui baixas elevações.

Mapa 2 - Mapa hipsômetro da área de estudo



Fonte: Adaptado do INPE (2011); IBGE (2009).

Na região de estudo predomina a caatinga hiperxerófila de porte arbóreo baixo ou arbóreo arbustivo. A vegetação da caatinga possui alta capacidade de adaptação à escassez

hídrica, uma vez que seus recursos bioquímicos e físicos a tornam altamente adaptada aos longos períodos de estiagem da região (RIBEIRO, 2014).

De acordo com Francisco (2010), na área ocorrem os Neossolos Litólicos Eutróficos, fase pedregosa substrato gnaisse e granito, e os Vertissolos apresentando relevo suave ondulado e ondulado, predominantemente nas partes mais baixas no entorno da drenagem, e os Planossolos Nátricos, relevo plano e suave ondulado, e a predominância de solos Luvisolos Crômicos bem desenvolvidos, em relevo suave ondulado.

A agricultura se baseia na agricultura familiar com o plantio de espécies como feijão macassá ou de corda e o milho (*Zea mays*), ainda nas culturas de batata-doce, fava, algodão herbáceo, mamona, mandioca, milho, tomate, feijão, banana, coco, goiaba, manga e sisal. A pecuária está embasada na criação extensiva de rebanhos, por ordem de importância: caprino, bovino, ovino, suíno, equino, asinino e muares. Na última década, apresenta-se uma crescente no quantitativo aviário (RIBEIRO, 2014).

4.2 REMOÇÃO DE NUVENS E MOSAICO SENTINEL-2

O processamento dos dados foi executado pelo *Code Editor* do GEE a partir do *script* desenvolvido na linguagem *JavaScript*. Para a remoção de nuvens, foi aplicado a metodologia de Spinosa *et al.* (2023), adaptado para este estudo, foram usados os produtos Sentinel-2 MSI de nível 2A. As imagens foram acessadas por meio do catálogo de dados do GEE "COPERNICUS/S2_SR". Todas as imagens disponíveis na região de interesse foram coletadas, segundo a grade de articulação do projeto Sentinel, órbita "24MYS". As imagens com alta cobertura de nuvens foram removidas. O limite de cobertura de nuvens foi definido em 30%. A máscara de nuvem foi aplicada às imagens usando o Scene Classification Map (SCL) e a banda QA60. A SCL permite rastrear ou marcar pixels defeituosos, enquanto a banda QA60 ajuda a distinguir entre nuvens opacas e cirrus. Para composição da imagem final foi aplicado um filtro de mediana no conjunto de imagens Sentinel-2, entre 01/01 a 31/12/2022, utilizando o comando "*ee.ImageCollection().median()*" resultando em uma imagem única e representativa do ano de 2022 da área de estudo.

4.3 TRANSFORMAÇÃO DE ÍNDICES ESPECTRAIS EM NOVAS BANDAS

Foram criadas as bandas dos índices NDVI, NDWI, NDBI e SAVI para a imagem Sentinel-2. Foi calculado os índices pelas função "*ee.Image.expression()*", e renomeadas as

bandas, pela função “*rename*”, assim sendo criada as bandas “NDVI”, “NDWI”, “NDBI” e “SAVI”.

4.4 COMPOSIÇÃO DOS CONJUNTOS DE DADOS USADOS PARA A CLASSIFICAÇÃO E COMPARAÇÃO

Além das bandas RGB da imagem Sentinel-2, foram utilizadas combinações adicionais para testar se elas aumentam a precisão dos mapas de uso e cobertura da terra. Foram testadas as combinações de bandas RGB-ÍNDICES (B4, B3, B2, NDVI, NDWI, NDBI e SAVI).

O Normalized Difference Vegetation Index (NDVI), foi criado para detectar a presença ou ausência de vegetação utilizando-se de comprimentos de onda do vermelho e vermelho próximo, destacando assim, a presença ou ausência de vegetação (ORNELLAS & LOPES, 2020). O Normalized Difference Water Index (NDWI) é um índice usado com eficiência para encontrar áreas de água e determinar o conteúdo de água nas plantas (LI *et al.*, 2013).

Nas imagens de satélite, muitas vezes é difícil distinguir entre áreas construídas e áreas de terra, e índices como o Normalized Difference Building Index (NDBI) é usado para aumentar a precisão na distinção desses tipos de uso da terra (ZHA *et al.*, 2003; DAMMALAGE; JAYASINGHE, 2019). O Soil Adjusted Vegetation Index (SAVI), foi desenvolvido na tentativa de minimizar a influência da reflectância do solo sobre o NDVI, incorporando a um fator L (HUETE, 1988). O fator de correção para minimizar as variações de brilho do solo, o torna preferível em regiões semiáridas, de vegetação tendencialmente mais esparsa onde a resposta do solo predomina em relação à resposta da vegetação (MACHADO *et al.*, 2011).

4.5 CONJUNTOS DE DADOS DE AMOSTRAS E CLASSES DE USO E COBERTURA DA TERRA

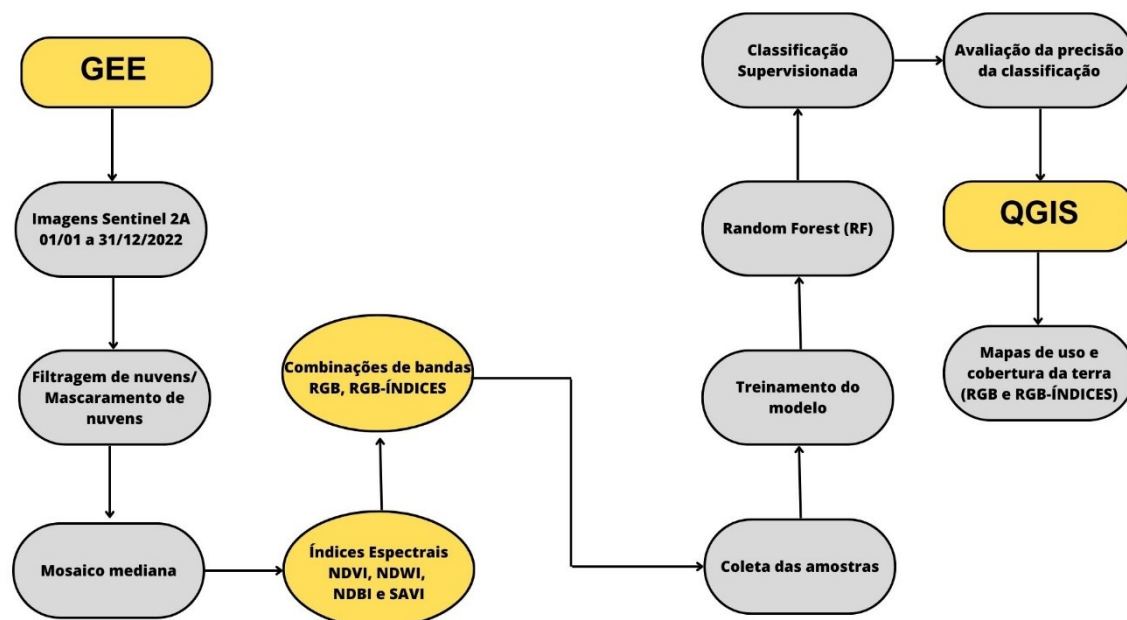
Em geral, uma alta precisão de classificação dos conjuntos de dados de SR exige grandes conjuntos de amostras de treinamento e validação. Portanto, foi gerado um grande número de amostras de treinamento e validação para gerenciar adequadamente os problemas de tamanhos de amostra insuficientes e grandes números de dimensões (HIDALGO *et al.*, 2021; TU *et al.*, 1998). Nesse estudo, o número total foi de 25.883 amostras, 18.509 amostras de treinamento e 7.374 amostras de validação, que foi definido com base em uma distribuição aleatória dos polígonos dentro das classes de uso e cobertura da terra adaptado de Alencar (2008), que incluía Vegetação densa (nativa), Água (corpos hídricos), Solo exposto, Vegetação rala mais solo exposto (pecuária extensiva e/ou cultivos agrícolas), Vegetação semidensa

(silvicultura/pecuária) e Urbana (área urbana). O conjunto de polígonos de cada classe foi aleatorizado e divididos em dois conjuntos independentes, sendo um de treinamento (70%) e outro de validação (30%). Com base no exposto, o classificador supervisionado RF foi usado para produzir mapas de uso e cobertura da terra e avaliar a precisão da classificação por meio de um conjunto de métricas. Como o mapeamento preciso das classes de uso e cobertura da terra com base em métodos de aprendizado de máquina requer um número suficiente de amostras de treinamento (MCCARTY *et al.*, 2020).

4.6 GERAÇÃO E VALIDAÇÃO DOS MAPAS DE USO E COBERTURA DA TERRA

Utilizaram-se as amostras de validação para avaliar a precisão do classificador atrelado as combinações das bandas, sendo a construção da Matriz de Confusão a primeira etapa. Em seguida, o Coeficiente Kappa (C.K), Acurácia Geral (A.G), Acurácia do Produtor (A.P) e Acurácia do Usuário (A.U), todos gerados pelo GEE. A partir das imagens obtidas, foram então exportadas as imagens para o software QGIS 3.00 para elaboração dos mapas. A metodologia dos procedimentos está descrito no Fluxograma 1.

Fluxograma 1 - Execução metodológica



Fonte: Autor (2023).

5 RESULTADOS E DISCUSSÃO

5.1 PRECISÃO DO RF COM AS COMBINAÇÕES DAS BANDAS

Como pode-se observar na matriz de confusão (Tabela 1), das 7.374 amostras de validação, 6.451 amostras foram classificadas corretamente. As 3 classes com maior confusão são Vegetação densa (VD) com 380 amostras omitidas, sendo 301 em Vegetação semidensa (VS), 60 em Água (A), 14 em Vegetação rala mais solo exposto (VRMSE) e 5 em Solo exposto (SE), Vegetação semidensa (VS) com 205 amostras omitidas, sendo 175 em Vegetação densa (VD), 16 em Vegetação rala mais solo exposto (VRMSE), 10 em Água (A) e 4 em Solo exposto (SE), e Vegetação rala mais solo exposto (VRMSE) com 146 amostras omitidas, sendo 51 em Vegetação semidensa (VS), 33 em Urbana (UR), 32 em Solo exposto (SE), 29 em Vegetação densa (VD) e 1 em Água (A).

Na Tabela 1, as bandas RGB apontam resultados de Acurácia Geral e Coeficiente Kappa com 84,51 e 82,30%, respectivamente, ficando abaixo de 85%. Retratam erros de omissão, dentre todas as classes, ou seja, classes que foram irregularmente mapeadas pelo algoritmo RF.

Tabela 1 - Matriz de confusão das bandas RGB do classificador RF

Classe	Referência						Total	A.U (%)
	VD	A	SE	VRMSE	VS	UR		
VD	2.159	36	0	29	175	0	2.399	83,98
A	60	1.044	2	1	10	0	1.117	95,85
SE	5	0	456	32	4	26	523	82,97
VRMSE	14	1	23	2.069	16	6	2.129	92,26
VS	301	4	0	51	625	0	981	72,24
UR	0	0	94	33	0	98	225	70,99
A.P (%)	88,24	93,31	87,47	97,53	59,96	42,92		
A.G (%)								84,51
C.K (%)								82,30

Legenda: VD: Vegetação densa; A: Água; SE: Solo exposto; VRMSE: Vegetação rala mais solo exposto; VS: Vegetação semidensa; UR: Urbana; A.P: Acurácia de precisão; A.U: Acurácia do usuário; A.G: Acurácia Geral; C.K: Coeficiente Kappa.

Ao observarmos a matriz de confusão na Tabela 2, as 3 classes com maior confusão são a Vegetação densa, Vegetação semidensa e Vegetação rala mais solo exposto. Nenhuma das classes obteve A.U ou A.P menor que 60%, significando que o classificador expressa uma qualidade razoável, isto representa que algoritmo de classificação indica que realizou corretamente a associação dos pixels às amostras de treinamento em todas as classes, como

também o usuário fez uma amostragem representativa para ambos os métodos (SANTANA, 2021; CARVALHO *et al.*, 2021).

Através da matriz de confusão pode-se observar que das 7.374 amostras de validação, 6.917 estão corretamente classificadas, representando valores de 91,90 e 89,98% de Acurácia Geral e Coeficiente Kappa, respectivamente, ficando acima de 85% (Tabela 2). Na combinação RGB-ÍNDICES, é possível observar que os números de pixels das classes em estudo aumentam, e o número de pixels associados às outras classes são reduzidos. Essa alteração pode ser confirmada pelo aumento do Coeficiente Kappa e Acurácia Global (MAGALHÃES *et al.*, 2023). Thomlinson *et al.* (1999), recomendam que a precisão de 85% é aceitável para a classificação do uso e cobertura da terra. Entretanto, para uma melhor avaliação da classificação é proposto por Stehman e Foody (2019), a aplicação da matriz de confusão, Coeficiente Kappa, Acurácia Geral e as precisões do usuário, do produtor, como proposto neste estudo.

Tabela 2 - Matriz de confusão das bandas RGB-ÍNDICES do classificador RF

Classe	Referência						Total	A.U (%)
	VD	A	SE	VRMSE	VS	UR		
VD	2.250	0	0	6	143	0	2.399	88,45
A	0	1.117	0	0	0	0	1.117	100
SE	0	0	487	13	0	23	523	94,35
VRMSE	4	0	12	2.099	7	7	2.129	96,60
VS	291	0	1	10	679	0	981	81,92
UR	0	0	19	21	0	185	225	94,08
A.P (%)	93,26	100	94,27	99,16	68,83	77,33		
A.G (%)							91,90	
C.K (%)							89,98	

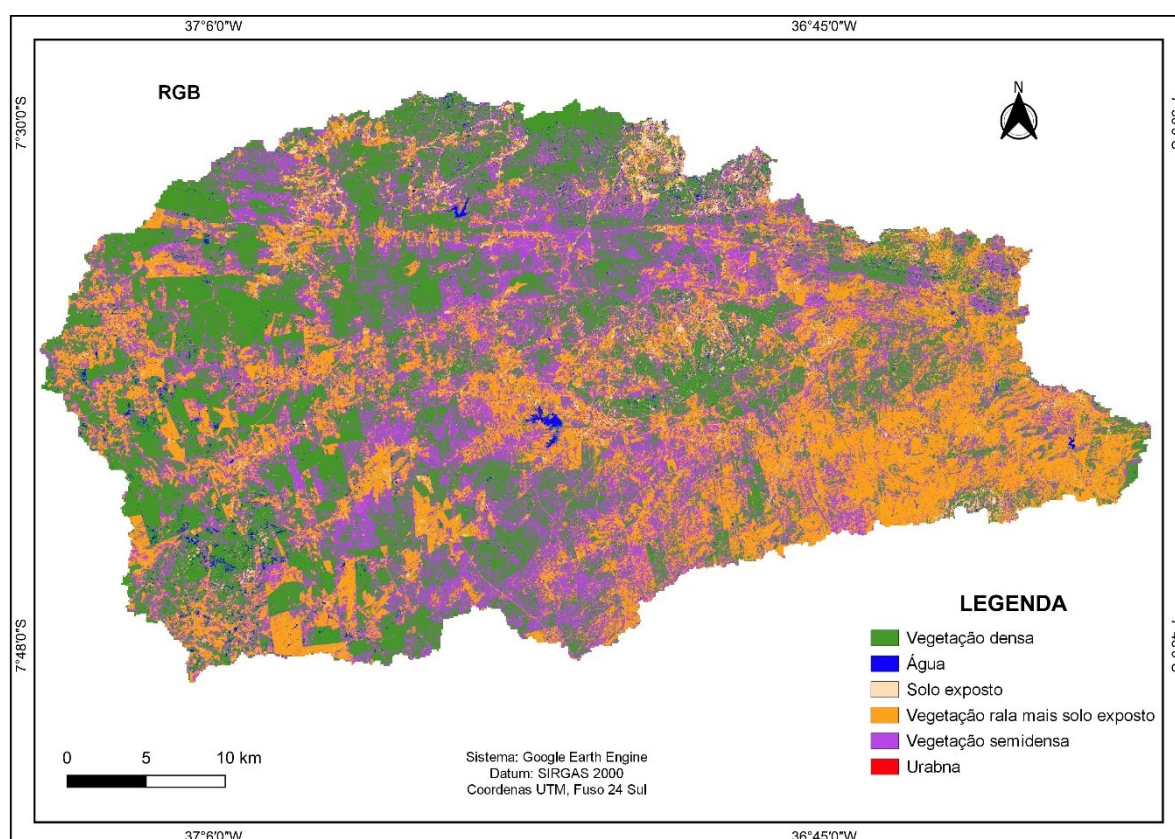
Legenda: VD: Vegetação densa; A: Água; SE: Solo exposto; VRMSE: Vegetação rala mais solo exposto; VS: Vegetação semidensa; UR: Urbana; A.P: Acurácia de precisão; A.U: Acurácia do usuário; A.G: Acurácia Geral; C.K: Coeficiente Kappa.

Resultados satisfatório são expostos por Oliveira (2021), ao utilizar o algoritmo RF através do GEE, ao estudar o uso e cobertura da terra no município de Luís Eduardo Magalhães-BA, onde obteve um Coeficiente Kappa de 99,00%. A autora relata que, o classificador RF apresenta vantagens entre os modelos de classificação por ser rápido na fase de treinamento e minimiza o efeito de ajustamento do modelo apenas para os dados de treinamento, porém apresenta como desvantagens possíveis buracos nos dados, e também a necessidade de uma grande quantidade de dados para o seu treinamento. Ao mesmo tempo em que, uma grande quantidade de árvore de decisão possa aumentar a chance de obter um resultado mais preciso, pode tornar a execução do algoritmo mais lenta.

5.2 USO E COBERTURA DA TERRA NA BHRS

Em relação aos 6 grupos de demonstração/amostragem os pixels estão dispersos em Vegetação densa com 2.399, Água (1.117), Solo exposto (523), Vegetação rala mais solo exposto (2.129), Vegetação semidensa (981) e Urbana (225) (Mapa3).

Mapa 3 - Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB



Fonte: Adaptado do Google Earth Engine (2023).

Observa-se que RF com a combinação das bandas RGB-ÍNDICES, proporciona os melhores resultados. Ou seja, uma menor confusão espectral no reconhecimento da cobertura da terra, principalmente na classificação da classe Urbana. Este resultado é corroborado com os índices de avaliação de classificação Acurácia Geral e Coeficiente Kappa calculados automaticamente pelo GEE para o método de classificação (Tabela 2).

De posse da classificação, buscou-se extrair os dados de área de cada classe, podendo ser observados na Tabela 3, a área das 6 classes, as mesmas foram calculadas considerando a contagem de pixels no que se refere à área total classificada da BHRS.

Tabela 3 - Resultados da classificação supervisionada do classificador RF pertencente a cada procedimento utilizado

CLASSE	RGB		RGB-ÍNDICES	
	Área (ha)	(%)	Área (ha)	(%)
VD	61.445,42	36,49	62.365,94	37,04
A	1.960,99	1,16	556,06	0,33
SE	4.109,26	2,44	2.957,00	1,76
VRMSE	48.988,76	29,10	49.819,10	29,59
VS	51.496,57	30,58	51.412,43	30,53
UR	373,45	0,22	1.263,91	0,75
Total	168.374,44	100,00	168.374,44	100,00

Legenda: VD: Vegetação densa; A: Água; SE: Solo exposto; VRMSE: Vegetação rala mais solo exposto; VS: Vegetação semidensa; UR: Urbana.

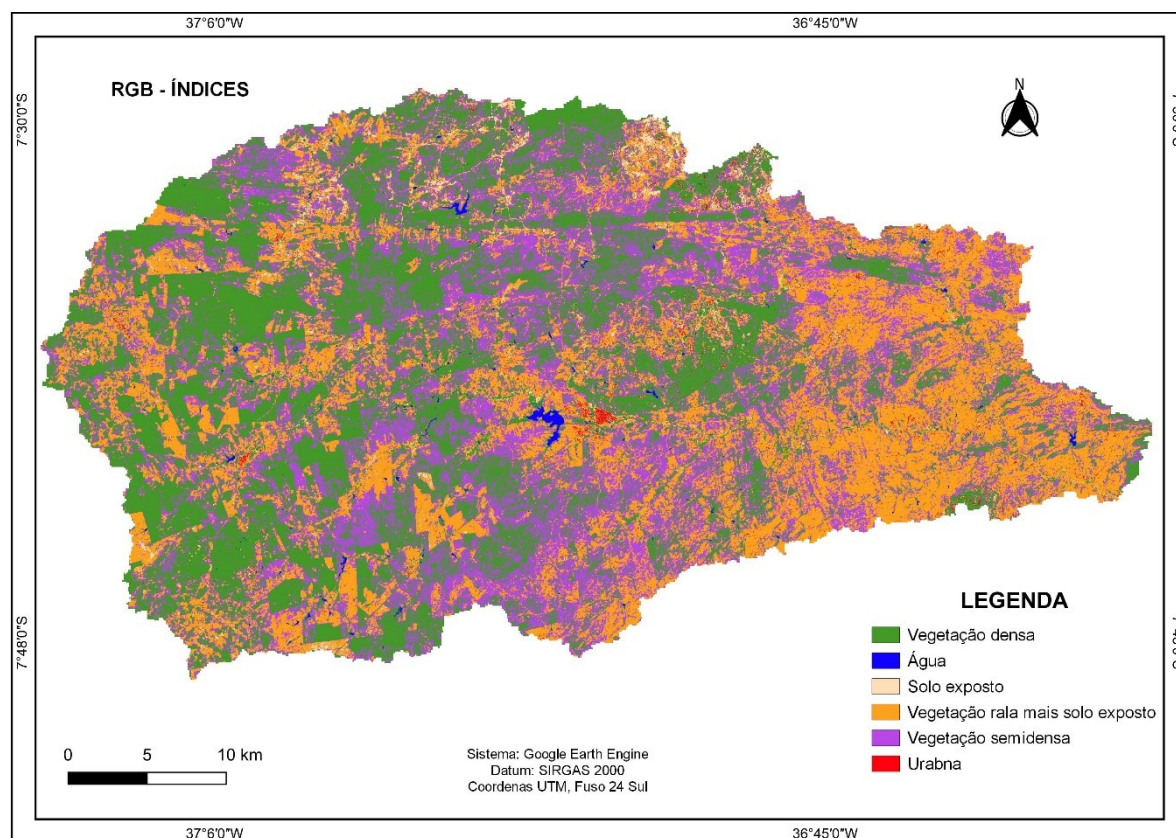
Ao somar as áreas de cada classe, se obtém o total de 168.374,44 ha, porém, o valor da área da BHRS é de aproximadamente 165.250,00 ha. Carvalho *et al.*, (2021), relatam que essa situação se deve ao processo de recorte da imagem satélite utilizada, onde considera o pixel como um elemento indivisível na imagem. Com isso um pixel localizado na divisa da BHRS não será partido, porém retido no decorrer do procedimento de recorte, sendo assim, colaborando com a elevação do valor total da área final.

De acordo com a Tabela 3, é possível verificar que a classe Vegetação densa apresenta 37,04% da área total, seguido pela classe Vegetação semidensa com 30,53%, Vegetação rala mais solo exposto com 29,59%, Solo exposto com 1,76%, Urbana com 0,75 e Água com 0,33%, oriundo do classificador RF com a combinação RGB-ÍNDICES.

5.3 RF COM A COMBINAÇÃO RGB-ÍNDICES

Conforme os dados da Tabela 3, e pela Figura 4 do mapa de uso e cobertura da terra referente ao algoritmo RF e a combinação das bandas RGB-ÍNDICES, mediante o ano de 2022, observa-se que a classe Vegetação densa (nativa), distribuída em 62.365,94 ha, com percentual de 37,04%, apresenta um aumento.

Mapa 4 - Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB-ÍNDICES



Fonte: Adaptado do Google Earth Engine (2023).

Ao confrontar com a pesquisa exercida por Santos (2015), o autor obteve o percentual de 10,57% da área da BHRS para o ano de 2013, mediante a classe Vegetação densa, o autor enfatiza que isto é decorrente, provavelmente, do incremento de áreas de pastagem que foram abandonadas e se encontram em pousio regenerando-se. Como também, boa parte dessa vegetação encontra-se em áreas de serra que, em função do difícil acesso, dificulta sua exploração (Figura 4), o mesmo relata que em períodos anteriores, essa classe de cobertura vem crescendo. Francisco *et al.* (2021), ressaltam que a exuberância da vegetação nativa na região semiárida é uma consequência da ocorrência da precipitação pluvial, de modo que a alta variabilidade climática identificada condiciona a cobertura vegetal na região.

Nota-se neste trabalho, a classe Água (corpos hídricos) abrange uma área de 556,06 ha, que corresponde a 0,33% da área total da BHRS, sendo principalmente evidenciado na Figura 5 pelo principal açude da região, o açude de Sumé. Alencar (2008) encontrou o percentual de 0,85% para a classe Água (corpos hídricos), mediante o ano de 2005, diante da área de estudo. Arelado a essas informações, em pesquisa executada no semiárido brasileiro, Rêgo (2018) ressalta que, a evaporação somada a má distribuição da água além das irregularidades e

concentrações pluviométricas durante o ano, implica na perda hídrica anualmente considerável nos reservatórios.

Andrade (2021b) atribui o valor da classe Solo exposto em 4,96%, enquanto que nesta pesquisa, atribui-se resultados da classe de 1,76%, apresentando um declínio. Já a classe Urbana (área urbana), observa-se que abrange uma área de 1.263,91 ha, que corresponde a 0,75 da área total da BHRS para o ano de 2022. Vale ressaltar que, a classe Solo exposto apresenta confusão espectral com áreas urbanizadas, isso vem se tornando comum em pesquisas aplicando Sensoriamento Remoto. Esse impasse é observado por Silva (2017), expondo que a assinatura espectral das áreas urbanas e solo exposto são muito similares. Isso é decorrente da variedade nos tipos de coberturas que apresentam as zonas urbanas, como o material utilizado para a fabricação de telhado das residências, calçadas, ruas, solo, dentre outros.

As áreas com menor vegetação na cobertura do solo, representado pela classe Vegetação rala mais solo exposto (pecuária extensiva e/ou cultivos agrícolas), compreende uma área de 49.819,10 ha, correspondente a 29,59% da área total da BHRS que se disseminam no decorrer da drenagem. Observa-se uma redução nesta classe ao afrontar com a pesquisa de Alencar (2008) que destacam um percentual de 36,51% desta, e reforçar que estas áreas são mais exploradas pela agricultura na região.

Souza *et al.* (2015) destacam que, a caatinga apresenta uma variabilidade natural em sua cobertura, mas que, no entanto, embora seja resiliente, pode sofrer com diversos tipos de pressões, tais como, o avanço da agropecuária, sobretudo a pecuária caprina quanto aos períodos de estiagem. As espécies nativas são fortemente degradadas em função da pecuária extensiva, predominantemente caprina, de modo que os impactos mais significativos são diretamente às espécies arbustivas e arbóreas perenifólias, a exemplo do Juazeiro (*Ziziphus joazeiro*) e Umbuzeiro (*Spondias tuberosa*) (SOUZA, 2008).

As áreas utilizadas para classe Vegetação semidensa (pecuária/silvicultura) englobam uma área de 51.412,43 ha, que corresponde a 30,53% da área de estudo para o ano de 2022. Observa-se um aumento nesta área, ao comparar com o trabalho de Alencar (2008), a mesma ressalta que esta área para o ano de 2005 representou 7,40% da área da BHRS. Santos (2015), destaca que isso se dá em função da alta exploração dessa vegetação. De acordo com Silva *et al.* (2014), na região semiárida do nordeste brasileiro, ocorre de maneira bastante rotineira e intensiva a retirada das espécies nativas da caatinga, para a utilização das áreas desmatadas nas atividades de agricultura e pecuária.

A análise sugere que o uso e a cobertura da terra na BHRS sofreram grandes mudanças nas últimas décadas, o que é semelhante aos resultados de pesquisas de outras áreas áridas e

semiáridas, como a bacia do rio Taperoá no nordeste do Brasil (SILVA *et al.*, 2020), o deserto costeiro noroeste do Egito (HALMY *et al.*, 2015) e o vale do Médio Suluh no norte da Etiópia (HISHE *et al.*, 2020).

6 CONCLUSÃO

A computação em nuvem GEE foi aplicada com sucesso para o mapeamento do uso e cobertura da terra, na BHRS.

O GEE mostrou considerável versatilidade e adaptabilidade devido às suas capacidades integrativas e sua plataforma eficiente para a escrita do script. Dentro do ambiente GEE, este trabalho desenvolveu e testou a classificação supervisionada baseada em duas combinações de bandas, RGB e RGB-ÍNDICES.

O melhor desempenho para o classificador RF foi identificado por meio de parâmetros estatísticos, Matriz de Confusão, C.K, A.G, A.P e A.U.

O classificador RF combinado com RGB-ÍNDICES teve um bom desempenho na distinção das classes, como na classificação de uso e cobertura da terra, obtendo uma menor confusão espectral e uma precisão acima de 89,98%, a adição de índices espectrais gerou níveis de acurácia significativamente satisfatório.

REFERÊNCIAS

- ALENCAR, M. L. S. **Os sistemas Hídricos, o bioma Caatinga e o social na bacia do Rio Sucuru: Riscos e vulnerabilidades.** 157f. Tese (Doutorado em Engenharia Agrícola). Departamento de Engenharia Agrícola. Universidade Federal de Campina Grande. CampinaGrande, 2008.
- AIRES, U. R. V. **Utilização de NDVI para análise da influência da modificação da cobertura vegetal no regime de vazões.** 97f. Dissertação (Mestrado em Engenharia Agrícola). Departamento de Engenharia Agrícola. Universidade Federal de Viçosa. Viçosa, 2018.
- ANDRADE, J.; CUNHA, J.; SILVA, J.; RUFINO, I.; GALVÃO, C. Evaluating single and multi-date Landsat classifications of land-cover in a seasonally dry tropical forest. **Remote Sensing Applications: Society and Environment**, v.22, e100515, 2021a.
- ANDRADE, J. M. **Classificação da cobertura do solo da caatinga: avaliação de abordagens em Machine Learning utilizando dados Landsat mono e multi – temporaris.** 69f. Dissertação (Mestrado em Engenharia Civil e Ambiental). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2021b.
- ARAÚJO, L. E.; SOUSA, F. D. A. S.; NETO, J. M. M.; SOUTO, J. S.; REINALDO, L. R. L. R. Bacias hidrográficas e impactos ambientais. **Qualitas Revista Eletrônica**, v.8, p.1-18, 2009.
- AIAZZI, B.; ALPARONE, L.; BARONTI, S.; SELVA, M. Twenty-five years of pansharpening. **Signal and Image Processing for Remote Sensing**, p.533-548, 2012.
- ALDIANSYAH, S.; SAPUTRA, R. A. Comparison of machine learning algorithms for land use and land cover analysis using Google Earth Engine (Case study: Wanggu watershed). **International Journal of Remote Sensing and Earth Sciences**, v.19, n.2, p.197-210, 2023.
- AUNE-LUNDBERG, L.; STRAND, G. H. Comparison of variance estimation methods for use with two-dimensional systematic sampling of land use/land cover data. **Environmental Modelling & Software**, v.61, p.87-97, 2014.
- AMIRRUDDIN, A. D.; MUHARAM, F. M.; ISMAIL, M. H.; ISMAIL, M. F.; TAN, N. P.; KARAM, D. S. Hyperspectral remote sensing for assessment of chlorophyll sufficiency levels in mature oil palm (*Elaeis guineensis*) based on frond numbers: Analysis of decision tree and random forest. **Computers and Electronics in Agriculture**, v.169, e105221, 2020.
- BREIMAN, L. Random forests. **Machine Learning**, v.45, p.5-32, 2001.
- BARROS, L. H. V. **Compartimentos do relevo na Bacia Hidrográfica do Rio Catu (RN): uma abordagem cartográfica por meio de geotecnologias.** 84f. Trabalho de Conclusão de Curso (Graduação em Geografia). Departamento de Geografia. Universidade Federal do Rio Grande do Norte. Natal, 2021.
- BARBOSA, R. B. G.; RIBEIRO, G. N.; FRANCISCO, P. R. M.; ARRUDA, D. A.; ALMEIDA, R. S.; LEITE, N. M. G. Geotecnologias aplicadas ao estudo da cobertura vegetal em bacia hidrográfica: uso do software “R”. **Revista Geama**, v.7, n.1, p.34-43, 2021.

BARBOSA, C. C. F.; NOVO, E. M. L. M.; MARTINS, V. S. M. **Introdução ao Sensoriamento Remoto de Sistemas Aquáticos: Princípios e Aplicações**. São José dos Campos: INPE, 2019. 161p.

CHAGAS, M. G. S. **Condição biológica da vegetação em ecossistemas costeiros e do Sertão do Pajeú em Pernambuco**. 123f. Tese (Doutorado em Desenvolvimento e Meio Ambiente). Centro de Filosofia e Ciências Humanas. Universidade Federal de Pernambuco. Recife, 2012.

CONGALTON, R. G.; ODERWALD, R. G.; MEAD, R. A. These techniques allow the Landsat data user to quantitatively compare the different aspects of image processing and to determine which perform better under varied conditions. **Photogrammetric Engineering & Remote Sensing**, v.49, n.12, p.1671-1678, 1983.

COSTA, H.; FOODY, G. M.; BOYD, D. S. Supervised methods of image segmentation accuracy assessment in land cover mapping. **Remote Sensing of Environment**, v.205, p.338–351, 2018.

CARVALHO, W. S.; MAGALHÃES FILHO, F. J. C.; SANTOS, T. L. Uso e cobertura do solo utilizando a Plataforma Google Earth Engine (GEE): Estudo de caso em uma Unidade de Conservação. **Brazilian Journal of Development**, v.7, n.2, p.15280-15300, 2021.

CASTANHO, A. D.; COE, M.; ANDRADE, E. M.; WALKER, W.; BACCINI, A.; CAMPOS, D. A.; FARINA, M. A close look at above ground biomass of a large and heterogeneous Seasonally Dry Tropical Forest - Caatinga in North East of Brazil. **Anais da Academia Brasileira de Ciências**, v.92, n.1, p.1-18, 2020.

CHU, D. Fractional vegetation cover. In: CHU, D. (ed). Remote sensing of land use and land cover in mountain region: a comprehensive study at the central Tibetan Plateau. **Singapore: Springer**, p.195–207. 2020.

CAVALCANTE, J. C.; LIMA, A. M. M. Análise do uso e cobertura da terra na bacia hidrográfica do rio Mocajuba-PA. **Revista de Geografia e Interdisciplinaridade**, v.5, n.18, e12215, 2019.

CHANG, N. B.; BAI, K. **Multisensor Data Fusion and Machine Learning for Environmental Remote Sensing**; CRC Press: Boca Raton, FL, USA, 2018. 489p.

DINIZ, R. R. S.; ALENCAR, M. L. S.; MEDEIROS, S. A.; GUERRA, H. O. C.; SALES, J. C. R. Índice de anomalia de chuvas da Microrregião do Cariri Ocidental Paraibano. **Revista Brasileira de Geografia Física**, v.13, n.6, p.2628-2640, 2020.

DEMIDOVA, L. A.; KLYUEVA, I. A.; PYLKIN, A. N. Hybrid approach to improving the results of the SVM classification using the random forest algorithm. **Procedia Computer Science**, v.150, p.455–461, 2019.

DAMMALAGE, T. L.; JAYASINGHE, N. T. Land-use change and its impact on urban flooding: a case study on Colombo District Flood on may 2016. **Engineering, Technology & Applied Science Research**, v.9, n.2, p.3887–3891, 2019.

ESRI. **Mapa Topográfico Mundial** (2022). Disponível em: <https://www.arcgis.com/home/item.html?id=30e5fe3149c34df1ba922e6f5bbf808f>. Acesso em: 21 jun. 2023.

ESTRABIS, N. V.; MARCATO JUNIOR, J.; PISTORI, H. Mapeamento da vegetação nativa do cerrado na região de Três Lagoas-MS com o Google Earth Engine. **Revista Brasileira de Cartografia**, v.71, p.702-725, 2019.

FAGUA, J. C.; RAMSEY, R. D. Geospatial modeling of land cover change in the Chocó-Darien global ecoregion of South America; One of most biodiverse and rainy areas in the world. **Plos One**, v.14, n.2, e0211324, 2019.

FRATELLO, M.; TAGLIAFERRI, R. Decision trees and random forests. **Encyclopedia of Bioinformatics and Computational Biology: ABC of Bioinformatics**, v.1, p.374–383, 2018.

FU, D.; XIAO, H.; SU, F.; ZHOU, C.; DONG, J.; ZENG, Y.; YAN, K.; LI, S.; WU, J.; WU, W.; YAN, F. Remote sensing cloud computing platform development and Earth science application. **National Remote Sensing Bulletin**, v.25, n.1, p.220-230, 2021.

FRANCISCO, P. R. M. **Classificação e mapeamento das terras para mecanização do Estado da Paraíba utilizando sistemas de informações geográficas**. 122f. Dissertação (Mestrado em Manejo de Solo e Água). Centro de Ciências Agrárias. Universidade Federal da Paraíba. Areia, 2010.

FRANCISCO, P. R. M.; AYRES, G. D. J.; FARIAS, E. S. B.; MORAES NETO, J. M.; SILVA, V. F.; SANTOS, D.; OLIVEIRA, F. P. Detecção de mudanças da vegetação de caatinga da bacia hidrográfica do alto rio paraíba através de técnicas de geoprocessamento. *In:* (Org). FRANCISCO, P. R. M.; FURTADO, D. A.; FERREIRA, A. C. **Engenharia, Agronomia e Geociência 2014-2021**. Campina Grande: EPTEC, 2021. 193p.

FLORENZANO, T. G. **Imagens de Satélite para Estudos Ambientais**. São Paulo: Oficina de Textos, 2002. 97p.

FOODY, G. M. Explaining the unsuitability of the kappa coefficient in the assessment and comparison of the accuracy of thematic maps obtained by image classification. **Remote Sensing of Environment**, v.239, e111630, 2020.

GANEM, K. A.; BAPTISTA, G. M. M.; ROCHA, W. J. S. A. F.; VASCONCELLOS, R. N.; ROSA, M. R.; SOUZA, D. T. M. Comparação entre dados com e sem correção atmosférica na classificação da cobertura da Terra de uma área da Caatinga utilizando o Google Earth Engine. **Revista Brasileira de Cartografia**, v.69, n.6, p.1053-1074, 2017.

GANEM, K. A. **Classificação da cobertura do solo na Caatinga a partir de imagens do Landsat-8 e da ferramenta Google Earth Engine: uma comparação entre dados com e sem correção atmosférica**. 182f. Dissertação (Mestrado em Geociências). Instituto de Geociências. Universidade de Brasília. Brasília, 2017.

GOOGLE EARTH ENGINE (GEE). **A planetary-scale platform for Earth science data & analysis**. 2023. Disponível em: <https://earthengine.google.com/>. Acesso em: 21 jul. 2023.

GE, G.; SHI, Z.; ZHU, Y.; YANG, X.; HAO, Y. Land use/cover classification in an arid desert-oasis mosaic landscape of China using remote sensed imagery: Performance assessment of four machine learning algorithms. **Global Ecology and Conservation**, v.22, e00971, 2020.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v.202, p.18-27, 2017.

HALMY, M. W. A.; GESSLER, P. E.; HICKE, J. A.; SALEM, B. B. Land use/land cover change detection and prediction in the north-western coastal desert of Egypt using Markov-CA. **Applied Geography**, v.63, p.101-112, 2015.

HISHE, S.; BEWKET, W.; NYSSSEN, J.; LYIMO, J. Analysing past land use land cover change and CA-Markov-based future modelling in the Middle Suluh Valley, Northern Ethiopia. **Geocarto International**, v.35, n.3, p.225-255, 2020.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). **Remote Sensing of Environment**, v.25, n.3, p.295-309, 1988.

HIDALGO, D. R.; CORTÉS, B. B.; BRAVO, E. C. Dimensionality reduction of hyperspectral images of vegetation and crops based on self-organized maps. **Information Processing in Agriculture**, v.8, n.2, p.310-327, 2021.

IBGE. **Instituto Brasileiro de Geografia e Estatística**. 2009. Disponível em: <<http://www.ibge.gov.br/>>. Acesso em: 21 jul. 2023.

IBGE. **Instituto Brasileiro de Geografia e Estatística**. Malhas territoriais. 2021. Disponível em: <<https://www.ibge.gov.br/geociencias/organizacao-do-territorio/malhas-territoriais/15774-malhas.html>>. Acesso em: 10 abr. 2022.

INPE. **Instituto Nacional de Pesquisas Espaciais**. 2011. Disponível em: <<http://www.webmapit.com.br/inpe/topodata/>>. Acesso em: 21 jul. 2023.

JAMALI, B.; BACH, P. M.; CUNNINGHAM, L.; DELETIC, A. A Cellular Automata fast flood evaluation (CA- ffé) model. **Water Resources Research**, v.55, n.6, p.4936-4953, 2019.

KOTHARI, N. S.; MEHER, S. K. Semisupervised classification of remote sensing images using efficient neighborhood learning method. **Engineering Applications of Artificial Intelligence**, v.90, e103520, 2020.

KOLLI, M. K.; OPP, C.; KARTHE, D.; GROLL, M. Mapping of major land-use changes in the Kolleru Lake freshwater ecosystem by using LANDSAT satellite images in Google Earth Engine. **Water**, v.12, n.9, e2493, 2020.

LIU, D.; CHEN, N.; ZHANG, X.; WANG, C.; DU, W. Annual large-scale urban land mapping based on Landsat time series in Google Earth Engine and OpenStreetMap data: A case study in the middle Yangtze River basin. **Journal of Photogrammetry and Remote Sensing**, v.159, p.337-351, 2020.

LI, X.; MESSINA, J. P.; MOORE, N. J.; FAN, P.; SHORTRIDGE, A. M. MODIS land cover uncertainty in regional climate simulations. **Climate Dynamics**, v.49, n.11-12, p.4047-4059, 2017.

LI, W.; DU, Z.; LING, F.; ZHOU, D.; WANG, H.; GUI, Y.; SUN, B.; ZHANG, X. A comparison of land surface water mapping using the normalized difference water index from TM, ETM+ and ALI. **Remote Sensing**, v.5, n.11, p.5530-5549, 2013.

LYONS, M. B.; KEITH, D. A.; PHINN, S. R.; MASON, T. J.; ELITH, J. A comparison of resampling methods for remote sensing classification and accuracy assessment. **Remote Sensing of Environment**, v.208, p.145-153, 2018.

LI, J.; KNAPP, D. E.; LYONS, M.; ROELFSEMA, C.; PHINN, S.; SCHILL, S. R.; ASNER, G. P. Automated global shallow water bathymetry mapping using Google Earth Engine. **Remote Sensing**, v.13, n.8, e1469, 2021.

LAMINE, S.; PETROPOULOS, G. P.; SINGH, S. K.; SZABÓ, S.; BACHARI, N. E. I.; SRIVASTAVA, P. K.; SUMAN, S. Quantifying land use/land cover spatio-temporal landscape pattern dynamics from Hyperion using SVMs classifier and FRAGSTATS®. **Geocarto International**, v.33, n.8, p.862-878, 2018.

MAGALHÃES, N. R.; GOMES, A. R.; CORRÊA, D. L.; Análise de desempenho do classificador Random Forest na detecção de classes de uso e cobertura da terra em áreas de não floresta em Salvaterra/Pa. In: Simpósio Brasileiro de Sensoriamento Remoto, 20, 2023, Florianópolis. **Anais...** Florianópolis, 2023.

MIDEKISA, A.; HOLL, F.; SAVORY, D. J.; ANDRADE-PACHECO, R.; GETHING, P. W.; BENNETT, A.; STURROCK, H. J. Mapping land cover change over continental Africa using Landsat and Google Earth Engine cloud computing. **PloS One**, v.12, n.9, e0184926, 2017.

MARTÍNEZ-LÓPEZ, J.; CARREÑO, M. F.; PALAZÓN-FERRANDO, J. A.; MARTÍNEZ-FERNÁNDEZ, J.; ESTEVE, M. A. Remote sensing of plant communities as a tool for assessing the condition of semiarid Mediterranean saline wetlands in agricultural catchments. **International Journal of Applied Earth Observation and Geoinformation**, v.26, p.193-204, 2014.

MONTEIRO, F. P. **ClasSIS: Uma metodologia para classificação supervisionada de imagens de satélite em áreas de assentamento localizados na Amazônia**. 82f. Dissertação (Mestrado em Engenharia Elétrica). Instituto de Tecnologia. Universidade Federal do Pará. Belém, 2015.

MACHADO, C. C. C.; GALVÍNCIO, J. D.; OLIVEIRA, T. H. Análise espacial e temporal do IVAS e do albedo da superfície no município de São José do Sabugi-PB. **Geografia**, v.36, n.2, p.359-369, 2011.

MACDICKEN, K. G. Global forest resources assessment 2015: what, why and how. **Forest Ecology and Management**, v.352, p.3-8, 2015.

MARTINEZ, S.; MOLLICONE, D. From land cover to land use: A methodology to assess land use from remote sensing data. **Remote Sensing**, v.4, n.4, p.1024-1045, 2012.

MAO, L.; LI, M. Integrating Sentinel active and passive data to map land cover in a National Park from GEE platform. **Geomatics and Information Science of Wuhan University**, v.48, n.5, p.756-764, 2023.

MCCARTY, D. A.; KIM, H. W.; LEE, H. K. Evaluation of light gradient boosted machine learning technique in large scale land use and land cover classification. **Environments**, v.7, n.10, e84, 2020.

MA, L.; LI, M.; MA, X.; CHENG, L.; DU, P.; LIU, Y. A review of supervised object-based land-cover image classification. **Journal of Photogrammetry and Remote Sensing**, v.130, p.277-293, 2017.

MORAES NOVO, E. M. L. M. **Sensoriamento Remoto: Princípios e Aplicações**. 4. ed. São Paulo: Edgard Blucher, 2010. 388p.

NIAZMARDI, S.; HOMAYOUNI, S.; SAFARI, A.; MCNAIRN, H.; SHANG, J.; BECKETT, K. Histogram-based spatio-temporal feature classification of vegetation indices time-series for crop mapping. **International Journal of Applied Earth Observation and Geoinformation**, v.72, p.34-41, 2018.

ONOJEGHUO, A. O.; BLACKBURN, G. A.; WANG, Q.; ATKINSON, P. M.; KINDRED, D.; MIAO, Y. Rice crop phenology mapping at high spatial and temporal resolution using downscaled MODIS time-series. **GIScience & Remote Sensing**, v.55, n.5, p.659-677, 2018.

OLIVEIRA, E. C. **Mapeamento de uso e cobertura da terra utilizando a plataforma Google Earth Engine**. 91f. Trabalho de Conclusão de Curso (Graduação em Geografia). Centro de Filosofia e Ciências Humanas. Universidade Federal de Santa Catarina. Florianópolis, 2021.

OLORUNFEMI, J. F.; IDOWU, E. D.; ASHAOLU O. Remote Sensing and Geographic Information System in Development. In: TILAKASIRI, S. L. (ed.) **Geography in Development: Issues and Perspectives**: Stamford Lake, p.102-119. 2017.

ORNELLAS, J. L.; LOPES, E. R. N. NDVI aplicado nas alterações da reserva extrativista marinha Baía do Iguape. In: Congresso Brasileiro de Gestão Ambiental, 11, 2020, Vitória. **Anais...** Vitória, 2020.

MAGALHÃES, N. R.; GOMES, A. R.; CORRÊA, D. L.; Análise de desempenho do classificador Random Forest na detecção de classes de uso e cobertura da terra em áreas de não floresta em Salvaterra/Pa. In: Simpósio Brasileiro de Sensoriamento Remoto, 20, 2023, Florianópolis. **Anais...** Florianópolis, 2023.

PHAN, T. N.; KUCH, V.; LEHNERT, L. W. Land cover classification using Google Earth Engine and random forest classifier-The role of image composition. **Remote Sensing**, v.12, n.15, e2411, 2020.

PARAÍBA. Secretaria de Estado da Ciência e Tecnologia e do Meio Ambiente. Agência Executiva de Gestão de Águas do Estado da Paraíba, AESA. PERH-PB: **Plano Estadual de Recursos Hídricos: Resumo Executivo & Atlas**. Brasília, 2006. 112p.

RAHMAN, A.; ABDULLAH, H. M.; TANZIR, M. T.; HOSSAIN, M. J.; KHAN, B. M.; MIAH, M. G.; ISLAM, I. Performance of different machine learning algorithms on satellite image classification in rural and urban setup. **Remote Sensing Applications: Society and Environment**, v.20, e100410, 2020.

RIBEIRO, G. N. **Uso de geotecnologias no estudo da degradação das terras no município de Sumé-PB**. 128f. Tese (Doutorado em Engenharia Agrícola). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2014.

RÊGO, A. T. A. **Sistemas de captação e armazenamento de água pluvial e utilização de mecanismos alternativos para controle da evaporação no semiárido brasileiro**. 63f. Trabalho de Conclusão de Curso (Bacharel em Ciência e Tecnologia). Departamento de Engenharia e Ciências Ambientais. Universidade Federal Rural do Semi-Árido. Mossoró, 2018.

RIBEIRO, E. P.; NOBREGA, R. S.; FILHO, F. O. M.; MOREIRA, E. B. Estimativa dos índices de vegetação na detecção de mudanças ambientais na bacia hidrográfica do rio Pajeú. **Geosul**, v.31, n.62, p.59-92, 2016.

SALLO, F. D. S.; FRANÇA, M. S. D.; MORAIS, D. M. D.; RODRIGUES, R.; BIUDES, M. S. Estimativa de componentes do balanço de radiação em diferentes tipos de uso e cobertura do solo. **Revista Ambiente & Água**, v.9, p.347-358, 2014.

SZANTOI, Z.; ESCOBEDO, F. J.; ABD-ELRAHMAN, A.; PEARLSTINE, L.; DEWITT, B.; SMITH, S. Classifying spatially heterogeneous wetland communities using machine learning algorithms and spectral and textural features. **Environmental Monitoring and Assessment**, v.187, n.5, p.1-15, 2015.

SUJATHA, E. R.; SRIDHAR, V. Spatial Prediction of Erosion Risk of a small mountainous watershed using RUSLE: A case-study of the Palar sub-watershed in Kodaikanal, South India. **Water**, v.10, n.11, e1608, 2018.

SRIDHAR, V.; KANG, H.; ALI, S. A. Human-induced alterations to land use and climate and their responses for hydrology and water management in the Mekong River Basin. **Water**, v.11, n.6, e1307, 2019.

SOUZA, B. I. D.; ARTIGAS, R. C.; LIMA, E. R. V. D. Caatinga e desertificação. **Mercator (Fortaleza)**, v.14, p.131-150, 2015.

SOUZA, B. I. **Cariri paraibano: do silêncio do lugar à desertificação**. 198f. Tese (Doutorado em Geografia). Instituto de Geociências. Universidade Federal do Rio Grande do Sul. Porto Alegre, 2008.

STEHMAN, S. V. Selecting and interpreting measures of thematic classification accuracy. **Remote Sensing of Environment**, v.62, n.1, p.77-89, 1997.

STEHMAN, S. V.; FOODY, G. M. Key issues in rigorous accuracy assessment of land cover products. **Remote Sensing of Environment**, v.231, e111199, 2019.

SRIDHAR, V.; ALI, S. A.; SAMPLE, D. J. Systems analysis of coupled natural and human processes in the Mekong River basin. **Hydrology**, v.8, n.3, e140, 2021.

SANTOS, E. I.; ALENCAR, M. L. S.; SCHRAMM, V. B.; SANTOS, J. S.; NASCIMENTO, M. T. C. C. Uso de geotecnologias no estudo da degradação das terras da bacia do rio Sucuru, na Paraíba. **Ciência e Natura**, v.42, e57, 2020.

SANTOS, E. I. **Uso de geotecnologias no estudo dos recursos naturais da bacia do rio sucuru, sub-bacia do rio Paraíba**. 75f. Trabalho de Conclusão de Curso (Graduação de Tecnologia em Agroecologia). Centro de Desenvolvimento Sustentável do Semiárido. Universidade Federal de Campina Grande. Sumé, 2015.

SOUSA, J. H. S.; MOREIRA, A. R.; NASCIMENTO, A. A.; RIBEIRO, G. N.; NETO, J. N. O.; PRADO JÚNIOR, L. S. Assessment of land use and cover in the Sucuru Watershed using Google Earth Engine. **Revista Verde de Agroecologia e Desenvolvimento Sustentável**, v.17, n.4, p.235-241, 2022.

SPINOSA, A.; FUENTES-MONJARAZ, M. A.; EL SERAFY, G. Assessing the Use of Sentinel-2 Data for Spatio-Temporal Upscaling of Flux Tower Gross Primary Productivity Measurements. **Remote Sensing**, v.15, n.3, e562, 2023.

SILVA, J. N. C. **Análise temporal de índices de vegetação no apoio à classificação de imagens: cobertura do solo na Bacia Hidrográfica do Rio Sucuru**. 109f. Dissertação (Mestrado em Recursos Naturais). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2017.

SILVA, M. B. R.; AZEVEDO, P. V.; ALVES, T. L. B. Análise da degradação ambiental no alto curso da bacia hidrográfica do Rio Paraíba. **Boletim Goiano de Geografia**, v.34, n.1, p.35-53, 2014.

SANTANA, I. L. **Classificação do uso e cobertura da terra utilizando algoritmo de aprendizado de máquina no Google Earth Engine para o semiárido de Pernambuco**. 61f. Dissertação (Mestrado em Tecnologias Energéticas e Nucleares). Centro de Tecnologia e Geociências. Universidade Federal de Pernambuco. Recife, 2021.

SANTOS, M. L. F. **Identificação de áreas prioritárias para conservação da caatinga na bacia do Alto Curso do rio Paraíba/PB através do uso das geotecnologias**. 131f. Dissertação (Mestrado em Desenvolvimento e Meio Ambiente). Centro de Ciências Exatas e da Natureza. Universidade Federal da Paraíba. João Pessoa, 2018.

SILVA, L. P.; XAVIER, A. P. C.; SILVA, R. M.; SANTOS, C. A. G. Modeling land cover change based on an artificial neural network for a semiarid river basin in northeastern Brazil. **Global Ecology and Conservation**, v.21, e00811, 2020.

SAUSEN, T. M.; LACRUZ, M. S. P. **Sensoriamento Remoto para Desastres**. São Paulo: Oficina de Textos, 2015. 288p.

THOMLINSON, J. R.; BOLSTAD, P. V.; COHEN, W. B. Coordinating methodologies for scaling landcover classifications from site-specific to global: steps toward validating Global Map Products. **Remote Sensing of Environment**, v.70, n.1, p.16-28, 1999.

TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L.; ADELI, S.; BRISCO, B. Google Earth Engine for geo-big data applications: A meta-analysis and systematic review. **Journal of Photogrammetry and Remote Sensing**, v.164, p.152-170, 2020.

TSAI, Y. H.; STOW, D.; CHEN, H. L.; LEWISON, R.; AN, L.; SHI, L. Mapping vegetation and land use types in Fanjingshan National Nature Reserve using google earth engine. **Remote Sensing**, v.10, n.6, e927, 2018.

TU, T. M.; CHEN, C. H.; WU, J. L.; CHANG, C. I. A fast two-stage classification method for high-dimensional remote sensing data. **Transactions on Geoscience and Remote Sensing**, v.36, n.1, p.182-191, 1998.

WANG, J.; WU, Z.; WU, C.; CAO, Z.; FAN, W.; TAROLLI, P. Improving impervious surface estimation: an integrated method of classification and regression trees (CART) and linear spectral mixture analysis (LSMA) based on error analysis. **Geoscience & Remote Sensing**, v.55, n.4, p.583-603, 2018.

WANG, L.; DIAO, C.; XIAN, G.; YIN, D.; LU, Y.; ZOU, S.; ERICKSON, T. A. A summary of the special issue on remote sensing of land change science with Google earth engine. **Remote Sensing of Environment**, v.248, e112002, 2020.

XIONG, J.; THENKABAIL, P. S.; GUMMA, M. K.; TELUGUNTLA, P.; POEHNELT, J.; CONGALTON, R. G.; YADAV, K.; THAU, D. Automated cropland mapping of continental Africa using Google Earth Engine cloud computing. **Journal of Photogrammetry and Remote Sensing**, v.126, p.225-244, 2017.

XIE, S.; LIU, L.; ZHANG, X.; YANG, J.; CHEN, X.; GAO, Y. Automatic land-cover mapping using landsat time-series data based on Google Earth Engine. **Remote Sensing**, v.11, n.24, e3023, 2019.

XIAO, Y.; HAO, Q.; ZHANG, Y.; ZHU, Y.; YIN, S.; QIN, L.; LI, X. Investigating sources, driving forces and potential health risks of nitrate and fluoride in groundwater of a typical alluvial fan plain. **Science of the Total Environment**, v.802, e149909, 2022.

YANG, H.; LI, S.; CHEN, J.; ZHANG, X.; XU, S. The standardization and harmonization of land cover classification systems towards harmonized datasets: a review. **International Journal of Geo-Information**, v.6, n.5, e154, 2017.

YU, Q.; GONG, P.; CLINTON, N.; BIGING, G.; KELLY, M.; SCHIROKAUER, D. Object-based detailed vegetation classification with airborne high spatial resolution remote sensing imagery. **Photogrammetric Engineering & Remote Sensing**, v.72, n.7, p.799-811, 2006.

ZHA, Y.; GAO, J.; NI, S. Use of normalized difference built-up index in automatically mapping urban areas from TM imagery. **International Journal of Remote Sensing**, v.24, n.3, p.583-594, 2003.

ZHANG, Y. J. A review of recent evaluation methods for image segmentation. *In: International Symposium on Signal Processing and Its Applications*, 1, 6, 2001, Malásia. **Anais...** Malásia, 2001.