



José Hugo Simplicio de Sousa
George do Nascimento Ribeiro
Paulo Roberto Megna Francisco
João Miguel de Moraes Neto
Paulo da Costa Medeiros

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

***Classificação do uso e cobertura
da terra da bacia hidrográfica
do rio Sucuru utilizando o
Google Earth Engine e aplicação
do algoritmo Random Forest***



Dados Internacionais de Catalogação na Publicação (CIP)

C5697 Classificação do uso e cobertura da terra da bacia hidrográfica do rio Sucuru utilizando o Google Earth Engine e aplicação do algoritmo Random Forest/Sousa et al.

— Campina Grande: EPTEC, 2023.

84 f.: il. color.

Formato: PDF

Requisitos de sistema: Adobe Acrobat Reader

Modo de acesso: World Wide Web

Inclui bibliografia

ISBN: 978-65-00-77715-4

1. Sensoriamento remoto. 2. Sentinel-2. 3. Estatística. 4. Semiárido. I. Sousa, José Hugo Simplicio de. II. Ribeiro, George do Nascimento. III. Francisco, Paulo Roberto Megna. IV. Moraes Neto, João Miguel de. V. Medeiros, Paulo da Costa. VI. Título.

CDU 630

Os capítulos ou materiais publicados são de inteira responsabilidade de seus autores. As opiniões neles emitidas não exprimem, necessariamente, o ponto de vista do Editor responsável. Sua reprodução parcial está autorizada desde que cite a fonte.



Todo o conteúdo deste livro está licenciado sob a Licença de Atribuição Creative Commons. Atribuição-Não-Comercial-Não Derivativos 4.0 Internacional (CC BY-NC-ND 4.0).

2023 by Eptec

Copyright © Eptec

Copyright do texto © 2023 Os autores

Copyright da edição © 2023 Eptec

Direitos para esta edição cedidos à Eptec pelos autores.

Open access publication by Eptec

Créditos das Imagens da capa

Pixabay/Freepick

Editoração, Revisão e Arte da Capa

Paulo Roberto Megna Francisco

Conselho Editorial

Claudiomir Silva Santos (IFSULMINAS)

Djail Santos (CCA-UFPB)

Dermeval Araújo Furtado (CTRN-UFCG)

Flávio Pereira de Oliveira (CCA-UFPB)

George do Nascimento Ribeiro (CDSA-UFCG)

Gypson Dutra Junqueira Ayres (CTRN-UFCG)

João Miguel de Moraes Neto (CTRN-UFCG)

José Wallace Barbosa do Nascimento (CTRN-UFCG)

Lúcia Helena Garófalo Chaves (CTRN-UFCG)

Luciano Marcelo Fallé Saboya (CTRN-UFCG)

Newton Carlos Santos (UFRN)

Paulo da Costa Medeiros (CDSA-UFCG)

Paulo Roberto Megna Francisco (CTRN-UFCG)

Raimundo Calixto Martins Rodrigues (DEAG-UEMA)

Soahd Arruda Rached Farias (CTRN-UFCG)

Virgínia Mirtes de Alcântara Silva (CTRN-UFCG)

Viviane Farias Silva (CSTR-UFCG)

José Hugo Simplicio de Sousa
George do Nascimento Ribeiro
Paulo Roberto Megna Francisco
João Miguel de Moraes Neto
Paulo da Costa Medeiros

Classificação do uso e cobertura da terra da bacia hidrográfica do rio Sucuru utilizando o Google Earth Engine e aplicação do algoritmo Random Forest



1.a Edição
Campina Grande-PB
2023

REALIZAÇÃO




APOIO



Universidade Federal
de Campina Grande

SUMÁRIO

Introdução	6
Fundamentação Teórica	9
<i>Uso e Cobertura da Terra</i>	9
<i>Sensoriamento Remoto</i>	11
<i>Sentinel-2</i>	12
<i>Google Earth Engine</i>	13
<i>Índices espectrais</i>	15
<i>Temperatura da Superfície Terrestre</i>	15
<i>Precipitação – TerraClimate</i>	16
<i>Classificadores espectrais</i>	17
<i>Random Forest</i>	18
<i>Treinamento e avaliação da classificação</i>	18
Material e Métodos	21
<i>Remoção de nuvens e mosaico</i>	24
<i>Transformação de índices espectrais</i>	25
<i>Composição dos conjuntos de dados utilizados para a classificação e comparação</i>	25
<i>Conjuntos de dados de amostras e classes de uso e cobertura da terra</i>	26
<i>Geração e validação dos mapas de uso e cobertura da terra</i>	27
<i>Índices biofísicos</i>	28
Resultados e Discussão	30
<i>Precisão do RF com as combinações das bandas</i>	30
<i>Uso e cobertura da terra</i>	33
<i>RF com a combinação RGB-Índices</i>	36
<i>Análise da cobertura vegetal</i>	39
<i>Análise dos índices biofísicos</i>	46
Conclusão	52
Referências Bibliográficas	54
Curriculum dos Autores	82



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).

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) e conhecimento social para gestão de recursos naturais (SRIDHAR et al., 2021).

A utilização do Sensoriamento Remoto 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 e vegetal de uma região geográfica, em função de sua precisão, praticidade e caráter multiespectral (CHAGAS, 2012; RIBEIRO et al., 2016a; SALLO et al., 2014).

Barbosa et al. (2019), afirmam que o NDVI (*Normalized Difference Vegetation Index*) é um parâmetro, fornecido por Sensoriamento Remoto, importante para o monitoramento da vegetação. Além da cobertura vegetal, as tecnologias voltadas ao processamento de imagens de satélite têm sido úteis para monitorar a Temperatura da Superfície Terrestre - LST (*Land Surface Temperature*) (PIRES, 2015). O LST diz respeito ao fluxo de calor dado em função da energia que chega e sai do alvo, sendo uma variável importante para a compreensão das interações entre a atmosfera e a superfície terrestre (FERREIRA et al., 2017).

Além do NDVI e a LST, também é importante caracterizar a região de estudos mediante dados de precipitação, pois este é um dos fatores que causam modificações significativas tanto na cobertura vegetal quanto na temperatura da região (BECERRA et al., 2009). A precipitação é uma variável que também pode ser estudada por detecção remota. As estimativas de precipitação baseadas em satélite são fontes alternativas de informações para regiões extensas em que os dados de precipitação convencional são escassos ou até mesmo ausentes (RAO et al., 2014, FUNK et al., 2015, PAREDES-TREJO et al., 2017).

Para processar os dados utilizados nesta pesquisa foi utilizada a plataforma do Google Earth Engine (GEE) que é uma ferramenta inovadora de processamento digital de imagens, desenvolvida pela empresa Google (HOROWITZ, 2015). Esta ferramenta permite análises multitemporais e espaciais de uma forma rápida e eficiente por meio de linguagens de programação JavaScript e Python (GORELICK et al., 2017).

Este estudo tem como objetivo analisar as mudanças ambientais na Bacia Hidrográfica do rio Sucuru-PB entre 2001 e 2019, como também, avaliar a cobertura vegetal na mesma região através de índices biofísicos em períodos secos e chuvosos, além de buscar classificar o uso e cobertura da terra para o ano de 2022, usando algoritmos de classificação supervisionada, disponível na plataforma do Google Earth Engine.



FUNDAMENTAÇÃO TEÓRICA

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 Sensoriamento Remoto (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).

SENSORIAMENTO REMOTO

A popularização do uso do Sensoriamento Remoto 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).

De acordo com 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 Sensoriamento Remoto.

Chang e Bai (2018), definem que o Sensoriamento Remoto 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. Conforme 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 Sensoriamento Remoto.

O Sensoriamento Remoto 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 Sensoriamento Remoto são muitas conforme Olorunfemi et al. (2017), o Sensoriamento Remoto 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.

SENTINEL-2

A Agência Espacial Europeia (ESA) e a Astrium assinaram em abril de 2008 um contrato de € 195 milhões para fornecer o primeiro satélite de observação da Terra Sentinel-2, dedicado ao monitoramento do ambiente terrestre, como parte do programa europeu Global Monitoring for Environment and Security (GMES). O Sentinel-2 apoia a geração operacional de produtos como o mapeamento da cobertura do solo e uso do solo, detecção de mudanças e variáveis geofísicas. O objetivo da missão é a cobertura sistemática da superfície terrestre para produzir imagens sem nuvens, normalmente a cada 15 a 30 dias na Europa (GUNTER'S SPACE PAGE, 2020).

A Missão Sentinel-2 compreende uma constelação de dois satélites (Sentinel-2A e 2B) de órbita polar, colocados na mesma órbita sincronizada com

o Sol, divididos em 180° entre si. A resolução temporal de cada sensor é 10 dias, sendo que o Sentinel -2B atinge a mesma posição do Sentinel-2A após 5 dias de sua passagem. Fornecem imagens terrestres de média resolução espacial, espectral e temporal e visam assegurar a continuidade das observações LANDSAT e SPOT (ESA, 2021).

Os dados adquiridos, cobertura de missão e alta frequência de revisita permitem a geração de geoinformação em escala local, regional, nacional e internacional. Os dados são projetados para serem modificados e adaptados por usuários interessados em áreas temáticas como planejamento espacial, monitoramento agroambiental, monitoramento de água, monitoramento de floresta e vegetação, carbono terrestre, monitoramento de recursos naturais, monitoramento de safra global (ESA, 2021).

As resoluções da Missão Sentinel-2 e seu instrumento MSI de carga útil são três, a resolução temporal de um satélite em órbita, que é a frequência de revisita do satélite para um local específico, tendo como frequência de revisita de cada satélite Sentinel-2 a de 10 dias e a revisita da constelação combinada a de 5 dias. O Sentinel-2 é a primeira missão óptica de observação da Terra desse tipo a incluir três bandas na borda vermelha, que fornecem informações importantes sobre o estado da vegetação (ESA, 2021).

GOOGLE EARTH ENGINE

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 bigdata 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).

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).

ÍNDICES ESPECTRAIS

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).

TEMPERATURA DA SUPERFÍCIE TERRESTRE

A Temperatura da Superfície Terrestre - LST (Land Surface Temperature) é um dos fatores-chave na física do processo de superfície do planeta, combinando interações superfície-atmosfera e os fluxos de energia entre a atmosfera e o solo (GORGANI et al., 2013). É um fator

importante que reflete mudanças ambientais da superfície e influi nos processos físicos e químicos e atualmente é amplamente utilizado em solo, hidrologia, biologia e geoquímica (DENG et al., 2018).

Conforme Valor e Caselles (1996), a temperatura é um importante parâmetro em muitos modelos ambientais, por exemplo na troca de energia e água entre a superfície e a atmosfera. Para estimar a temperatura da superfície em escala regional ou global torna-se necessário o uso do Sensoriamento Remoto (DASH et al., 2002).

PRECIPITAÇÃO – TERRACLIMATE

O TerraClimate é um conjunto de dados de clima mensal e balanço hídrico climático para superfícies terrestres globais de 1958 a 2019. Os seus dados de precipitação não apresentam falhas, têm resolução temporal mensal e resolução espacial de aproximadamente $1/24^\circ$ (~ 4 km) (ABATZOGLOU et al., 2018).

O TerraClimate produz conjuntos de dados mensais de balanço de água de superfície usando um modelo de balanço hídrico climático de Thornthwaite-Mather modificado que incorpora evapotranspiração de referência, precipitação, temperatura e dados de capacidade de armazenamento de água do solo. Os seus dados têm resolução temporal mensal e resolução espacial de $1/24^\circ$ (~ 4 km) (ABATZOGLOU et al., 2018).

CLASSIFICADORES ESPECTRAIS

Um dos usos mais conhecidos do Sensoriamento Remoto 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).

RANDOM FOREST

O Random Forest (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).

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).

Conforme 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 predição 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., 2021). 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 predições 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).



MATERIAL E MÉTODOS

CARACTERIZAÇÃO DA ÁREA DE ESTUDO

A Bacia Hidrográfica do rio Sucuru representa parcela significativa da bacia do Alto rio Paraíba e está localizada no semiárido paraibano (Figura 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).

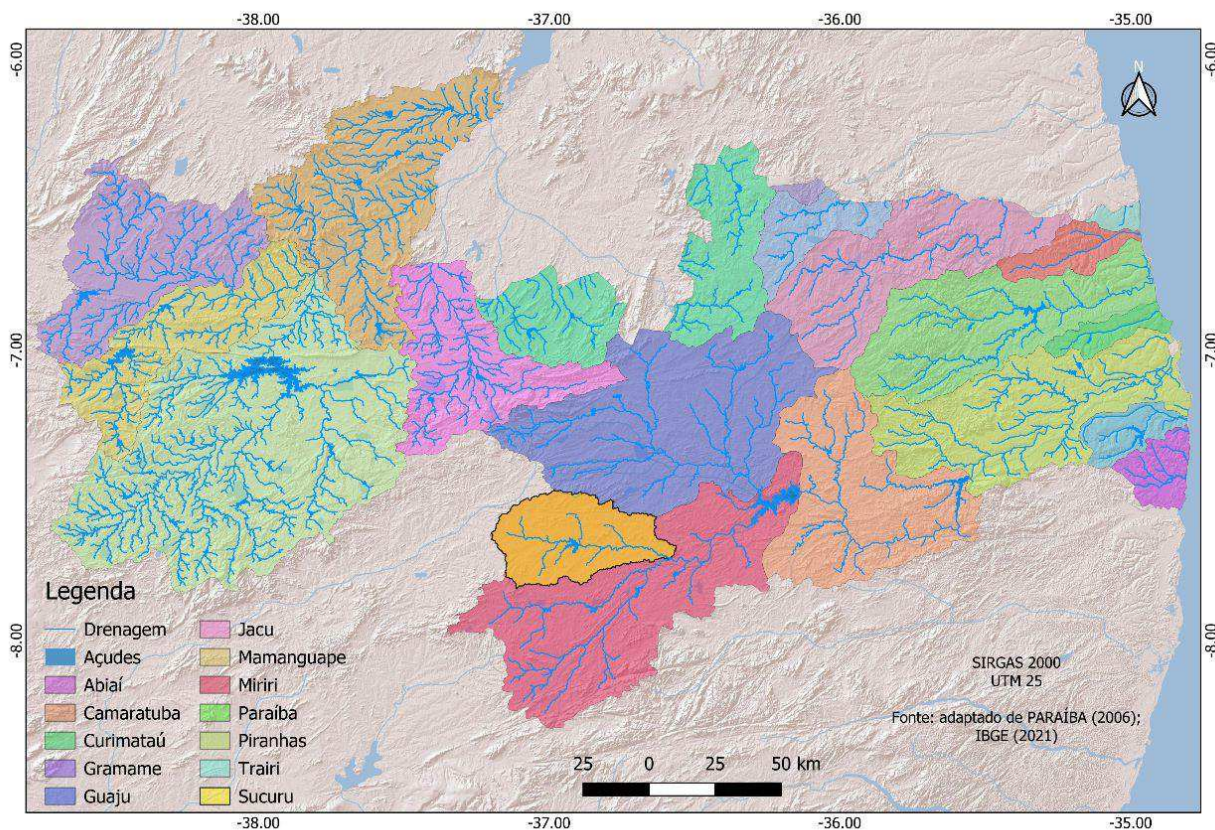


Figura 1. Localização da área de estudo

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

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). 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 bacia hidrográfica do rio Sucuru, observa-se na Figura 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.

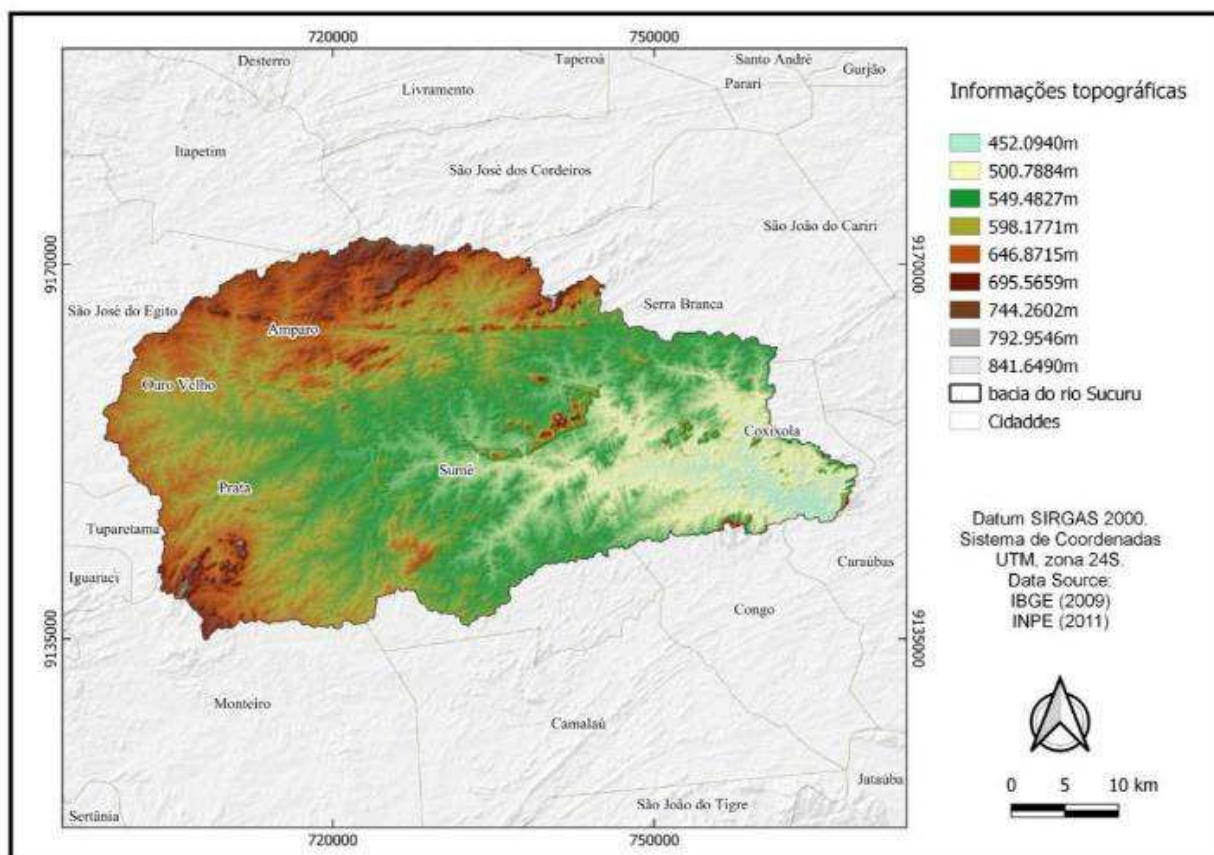


Figura 2. Mapa hipsômetro da área de estudo.

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 macassar ou de corda e o milho, 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).

REMOÇÃO DE NUVENS E MOSAICO

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.

TRANSFORMAÇÃO DE ÍNDICES ESPECTRAIS

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”.

COMPOSIÇÃO DOS CONJUNTOS DE DADOS UTILIZADOS 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).

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 Sensoriamento Remoto 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 incluiu 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 dividido 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).

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® 3.0 para elaboração dos mapas.

COBERTURA VEGETAL

Para o estudo da cobertura vegetal, foram utilizadas imagens do sensor multiespectral do Sentinel-2, com nível 1c, melhor nível de correção produzido de forma sistemática que inclui: projeção em sistema cartográfico utilizando Modelo Digital de Terreno; valores de reflectância em Topo de Atmosfera (TOA); reamostragem em grid padrão de 10, 20 e 60m (GSD) e inclusão de máscara de nuvem (ESA, 2015). Os satélites Sentinel-2A e 2B são satélites de imageamento multiespectral que geram imagens em alta resolução (com bandas de 10 a 60m) e com alta capacidade de revisita (5 dias) (DRUSCH et al., 2012).

Foi aplicado um filtro para remoção de pixels de nuvens nas imagens capturadas entre 01/01/2022 à 01/05/2022 e 01/06/2022 à 01/12/2022, referente ao período chuvoso e seco, respectivamente, e gerada uma imagem síntese dos períodos utilizando o valor da mediana de cada pixel. Rosa (2018) ressalta que, a utilização do valor da mediana é importante pois elimina pixels contaminados por ruídos causados por névoas, nuvem ou sombra de nuvem que

não tenham sido removidos no filtro inicial. A partir das imagens obtidas, foram realizados os cálculos dos índices espectrais e, então exportadas as imagens para o software QGIS® 3.0 para elaboração do layout.

ÍNDICES BIOFÍSICOS

Em relação aos parâmetros biofísicos, para análise do NDVI foram utilizadas imagens do sensor MODIS (MODIS/061/MOD13Q1), de 16 dias com resolução espacial de 250 m e para a análise da LST foram utilizadas imagens do sensor MODIS (MODIS/006/MOD11A2), de 8 dias com resolução espacial de 1.000 m para os anos de 2001 à 2019, respectivamente, como base por ser uma fonte gratuita cujos produtos já constam na plataforma do GEE (MOREIRA, 2022).

Os dados meteorológicos foram obtidos da Terra Climate University do conjunto de dados mensal de clima e balanço hídrico de Idaho - EUA em dados globais de superfícies de terra (IDAHO_EPSCOR/TERRACLIMATE) (ABATZOGLOU et al., 2018). Este conjunto de dados fornece a distribuição espacial de fatores climáticos pelo método de interpolação assistida pelo clima e água modelo de equilíbrio (PATEL et al., 2015; RAVANELLI et al., 2018).

O processamento na plataforma do GEE possibilitou a elaboração do código para obtenção dos valores de NDVI, LST e Precipitação na área de estudo. Na análise do NDVI, LST e Precipitação utilizou-se como referência o código adaptado por Moreira (2022), que para o NDVI, foram utilizados, primeiramente, os layers de indicadores de qualidade para mascarar os pixels de NDVI, mantendo apenas aqueles cujo índices de vegetação foram considerados gerados com boa qualidade. Então, foram filtrados os rasters para os dois

períodos selecionados, os valores dos pixels foram divididos por 10.000 para corresponderem ao intervalo padrão de -1 a 1. Para a visualização da imagem, optou-se por utilizar a média dos pixels em cada ano, e, para complementar a investigação, foi calculada a média total de NDVI na área de estudo em cada período. Além disso, como foram mascarados os pixels de baixa qualidade, estes não interferiram no cálculo. A presença de nuvens, dessa forma, não afetaria o resultado.

Semelhante ao procedimento realizado para a obtenção do NDVI, foram mascarados os pixels não considerados de boa qualidade, filtrados os períodos desejados e convertidos os valores de Kelvin para Grau Celsius (°C) levando em consideração o fator de escala informado. Para a visualização da imagem, foi calculada a média de cada pixel em cada período e, junto disso, a média de toda a região, bem como o valor máximo e mínimo observados em cada período (MOREIRA, 2022).

Similar ao realizado nos outros dois procedimentos, elaborou-se um código no qual foram determinados os períodos para a filtragem da área de estudo (MOREIRA, 2022). Para a obtenção dos valores de NDVI, LST e Precipitação em cada ano utilizou média aritmética. Os rasters (dados matriciais) gerados (NDVI, LST e Precipitação) na plataforma do GEE foram posteriormente exportados para o Microsoft Office Excel® 2013, para fins de elaboração dos gráficos (CAVALCANTE et al., 2020).



RESULTADOS E DISCUSSÃO

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, observa-se que resultados de Acurácia Geral e Coeficiente Kappa apresentam 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 se observar 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, o 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%. 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.

USO E COBERTURA DA TERRA

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) (Figura 3).

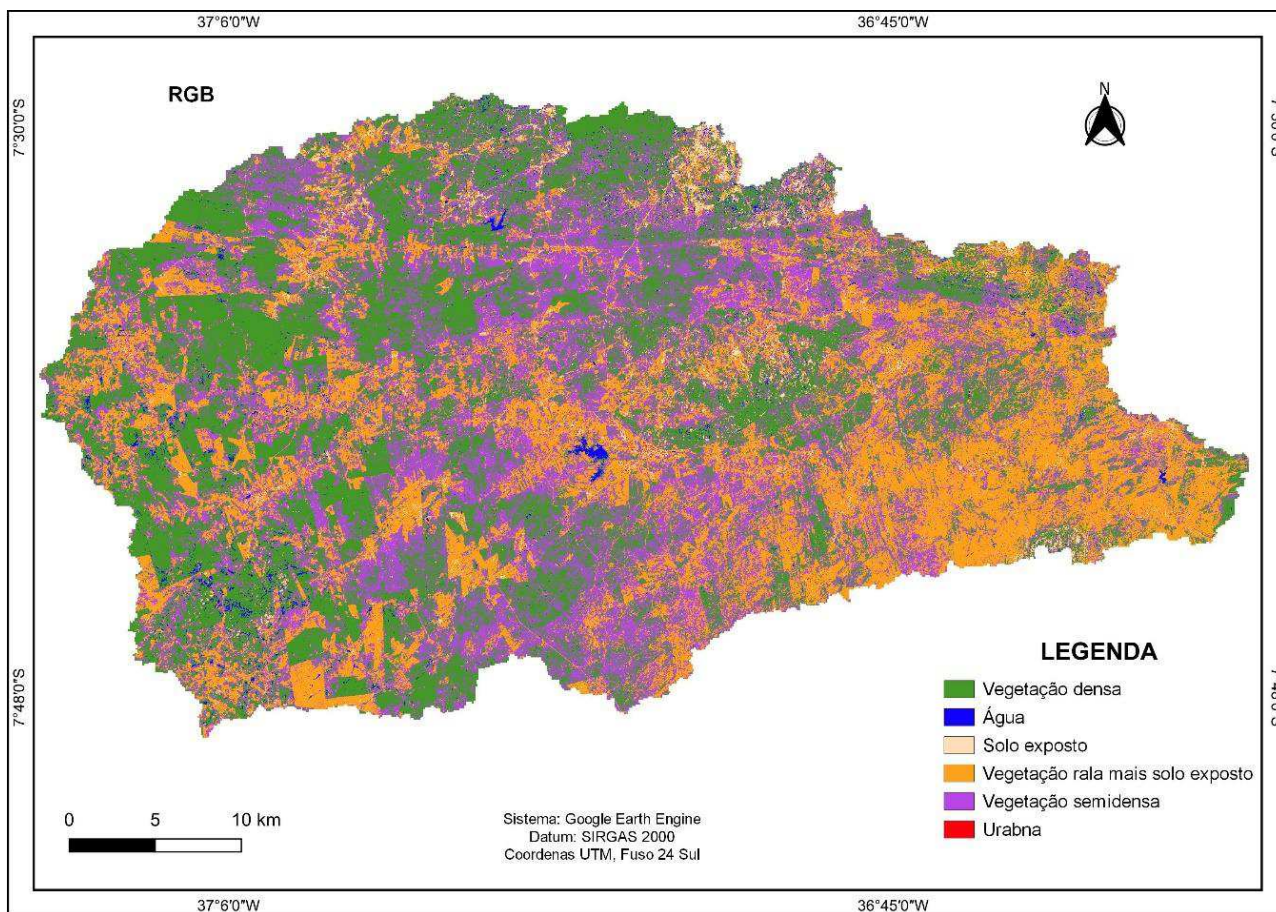


Figura 3. Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB. Fonte: Adaptado do Google Earth Engine (2023).

Observa-se que o 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 bacia hidrográfica do rio Sucuru.

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 bacia hidrográfica do rio Sucuru 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 bacia 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.

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.

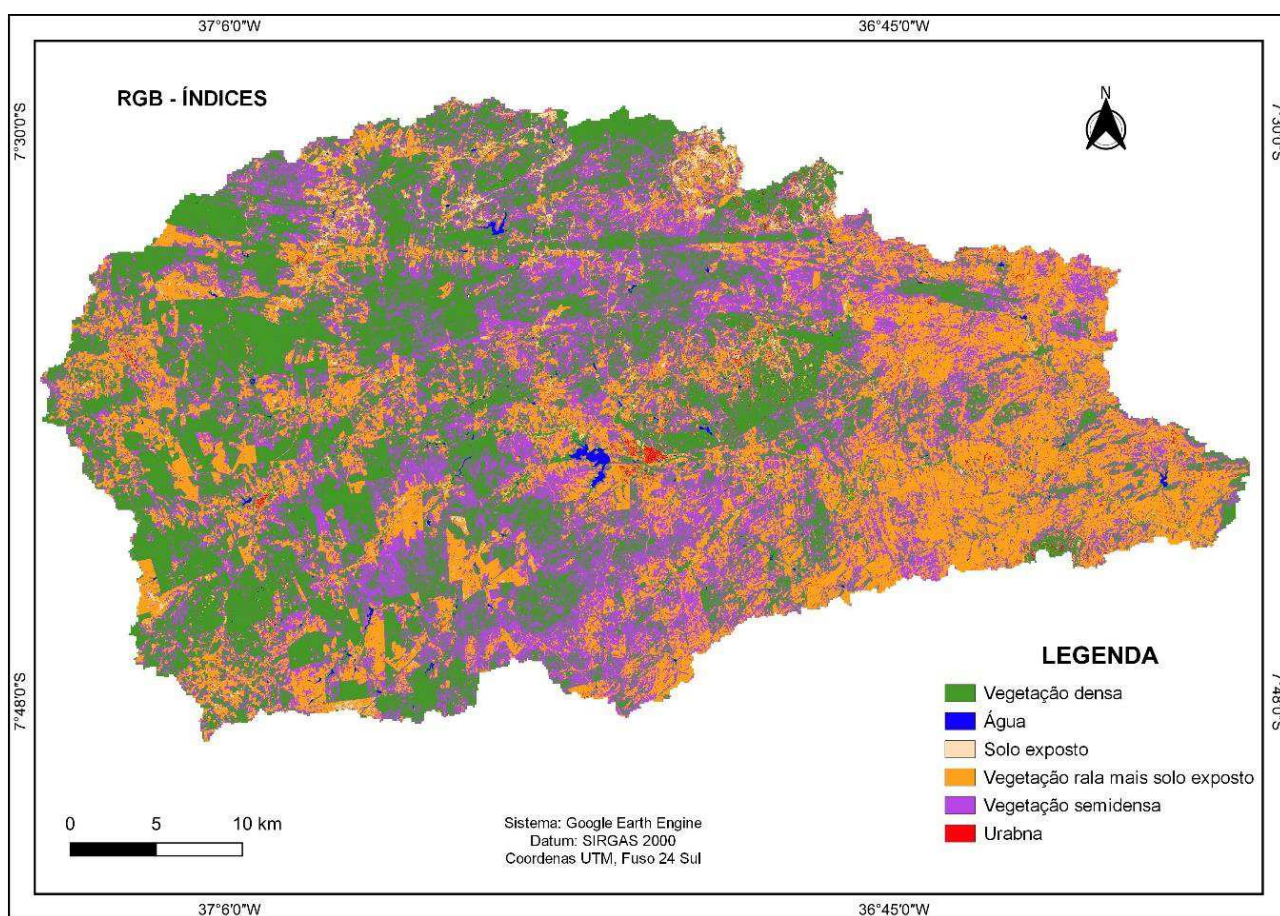


Figura 4. Mapa de uso e cobertura da terra referente ao classificador RF pertencente a combinação RGB-Índices.

Fonte: Adaptado do Google Earth Engine (2023).

Ao confrontar com a pesquisa elaborada por Santos (2015), o autor obteve o percentual de 10,57% da área da bacia hidrográfica do rio Sucuru 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, que a classe Água (corpos hídricos) abrange uma área de 556,06 ha, que corresponde a 0,33% da área total da bacia, 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. Atrelado 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 (2021) 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 bacia para o ano de 2022. Vale ressaltar que, a classe Solo exposto apresenta confusão espectral com áreas urbanizadas, isso vêm 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 bacia 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), o mesmo ressalta que esta área para o ano de 2005 representou 7,40% da área da bacia. 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 bacia 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., 2020a), o deserto costeiro noroeste do Egito

(HALMY et al., 2015) e o vale do Médio Suluh no norte da Etiópia (HISHE et al., 2020).

ANÁLISE DA COBERTURA VEGETAL

Na Figura 5, observam-se produtos do NDVI para a bacia, para o período o seco e chuvoso do ano de 2022, respectivamente.

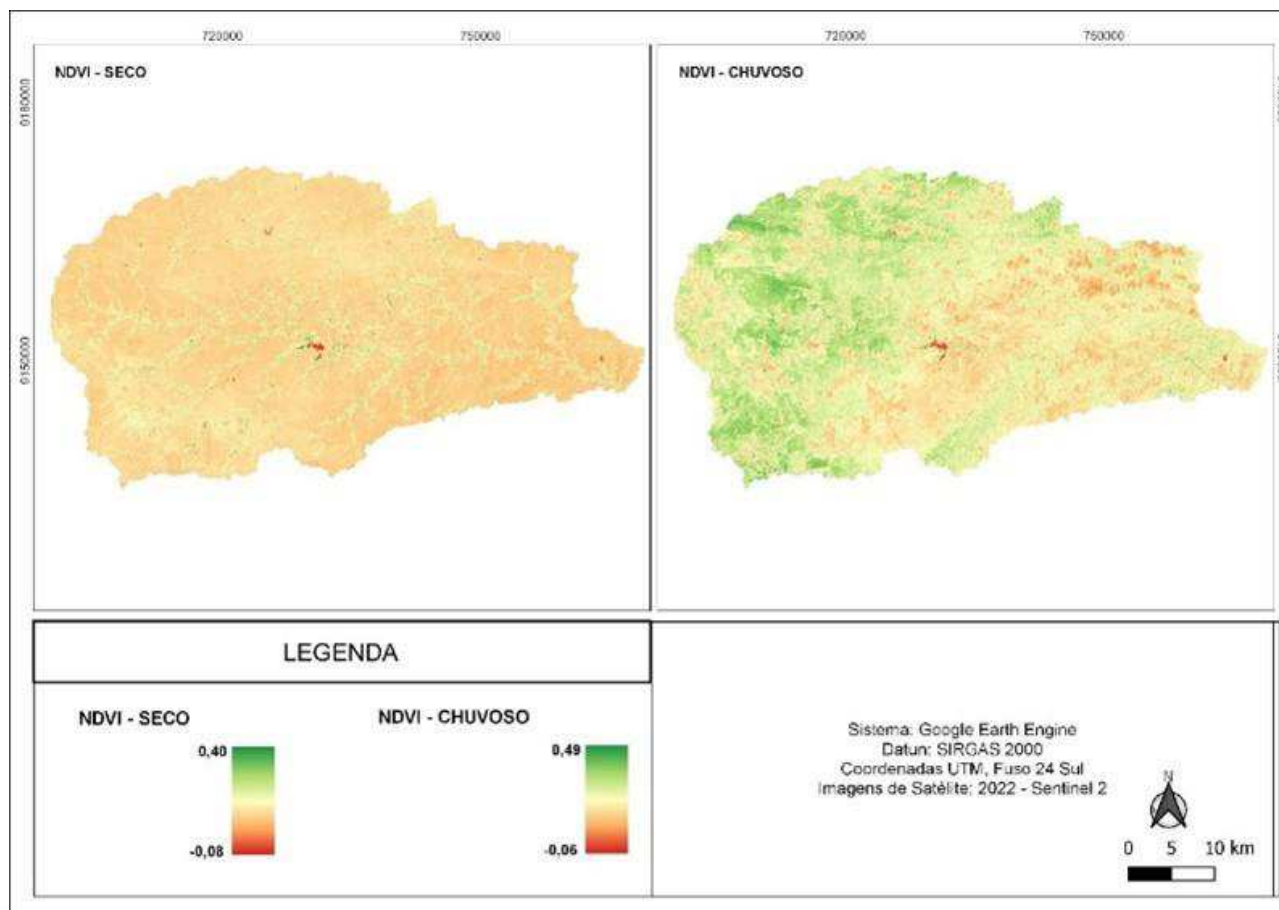


Figura 5. NDVI para o período seco e chuvoso do ano de 2022.

Fonte: Adaptado do Google Earth Engine (2023).

Durante o período seco, os valores máximo e mínimo de NDVI são -0,08 e 0,40 (Figura 5), delineando corpos d'água e áreas de pastagem e arbustos

presentes na área de estudo, respectivamente. Há concordância entre esses resultados obtidos e o trabalho realizado por Karaburun (2010), que observou que o NDVI possui propriedades que variam de $-1,0 \leq \text{NDVI} \leq 1,0$. Ainda para o autor, valores negativos de NDVI ($\text{NDVI} < 0$) indicam corpos d'água, valores muito baixos ($\text{NDVI} < 0,1$) correspondem as áreas inférteis, já valores considerados moderados ($0,2 \leq \text{NDVI} \leq 0,3$) representam áreas de pastagem e arbustos, enquanto ($0,6 \leq \text{NDVI} \leq 0,8$) expressam florestas tropicais e temperadas e indicam a presença de vegetação viva, e o solo exposto tem valor nulo ($\text{NDVI} = 0$). Dados semelhantes ao de Besalatpour et al. (2013), em pesquisa realizada na bacia hidrográfica altamente montanhosa de Bazoft, no sudoeste do Irã, constataram que o NDVI variou de $-0,31 \leq \text{NDVI} \leq 0,47$, mínimo e máximo, respectivamente.

Em estudo realizado por Barbosa et al. (2021), que aplicaram diferentes índices de vegetação na bacia hidrográfica do rio Sucuru, mediante o ano de 2016, os mesmos verificaram que o NDVI variou entre ($-0,2 \leq \text{NDVI} \leq 0,4$), confirmando, assim, os resultados deste estudo, onde o valor máximo é de 0,40 durante o período seco. Conforme Alves (2016), isso relaciona-se à época de imageamento da região, que corresponde ao período de precipitações pluviais mínimas, e também devido à própria vegetação da área, formada por Caatinga caducifólia arbustiva, que se caracteriza pela queda das folhas no período seco (agosto a dezembro).

Medeiros et al. (2022), em estudo elaborado no município de Patos-PB, afim de obter a resposta espectral do comportamento do NDVI e NDWI, relataram que o NDVI variou de $0,08 \leq \text{NDVI} \leq 0,28$, para o período seco de 2014. Gameiro et al. (2016), avaliaram a cobertura vegetal em Jaguaribe-CE utilizando índices de vegetação. O resultado trouxe imagens de períodos secos e úmidos da área de estudo que detectaram diferenças relevantes, incluindo perdas de vegetação natural para a agricultura.

Gandhi et al. (2015), avaliando o distrito de Vellore na Índia, encontraram valores de NDVI entre $0,1 \leq \text{NDVI} \leq 0,5$. Ainda para os autores, o NDVI tem sido bastante utilizado para analisar a relação entre a variabilidade espectral e as mudanças nas taxas de crescimento da vegetação, além de detectar às mudanças na cobertura vegetal, os valores mais baixos de NDVI são encontrados nos solos menos vegetados, porque a reflexão no solo é alta, dessa forma produz menores valores na faixa do infravermelho próximo e altos na faixa vermelha, portanto os valores do NDVI são baixos.

Lima (2021), aplicando NDVI no bioma Caatinga, para estimar o estoque de carbono e biomassa acima do solo, observou que na estação chuvosa ocorre um pico de reflectância na região do infravermelho, devido a interação com a clorofila, já na estação seca esse pico não ocorre, pois nesse período as árvores perdem suas folhas. Em termos de quantificação e caracterização quantitativa das características da cobertura vegetal, o NDVI é um indicador que está inteiramente relacionado ao crescimento da vegetação e distribuição espacial, que devido ao seu cálculo simples, ao fácil acesso aos parâmetros de cálculo e ampla faixa de monitoramento, é possível quantificar o crescimento das plantas com biomassa, cobertura vegetal, além do índice de área foliar (LI BINBIN et al., 2014).

Na Figura 5, observa-se os valores de NDVI variam de um máximo e mínimo de -0,06 e 0,49, respectivamente, para o período chuvoso na bacia no ano de 2022, sendo representados como corpos d'água e a presença de áreas de pastagem e arbustos presentes na área de estudo, respectivamente. Macedo (2019), estimando os índices de vegetação na unidade de conservação do parque estadual das Carnaúbas-CE, mediante o ano de 2018, obteve os valores máximos de NDVI de 0,58 para o período úmido, o mesmo enfatiza que essa característica se justifica pelo fato da presença de umidade, os índices sofrerem alterações.

Freitas et al. (2017), avaliando o comportamento da vegetação através do NDVI em Remanso-BA ao longo do ano de 2016. Os autores apresentaram

resultados com valores de NDVI alto no período chuvoso, enquanto no período seco os valores foram menores. Ficando evidente a diminuição de vegetação densa nos primeiros meses do ano e o aumento das áreas desprovidas de vegetação devido à carência de chuva. Silva et al. (2020b), avaliaram em uma região do bioma Caatinga a distribuição espaço-temporal do índice de vegetação de diferença normalizada (NDVI), para o período de 1998 a 2018, e observaram valores variando de $-0,283$ a $0,642$.

Existem alguns fatores que influenciam no crescimento da vegetação e por conseguinte afetam a resposta do NDVI, dentre os quais a refletividade das folhas, que possivelmente mudam com a idade, podem levar de um a dois meses para atingir a expansão total com maior refletividade, e as precipitações afetando os valores dos índices de vegetação, ao promoverem a redução da radiação refletida pelo solo e no caso da caatinga, especificamente, elevam o índice de área foliar da vegetação após um evento chuvoso (YANG et al., 2014; FERREIRA, 2013).

Maldonado (2005) acentua que, a diferença de valores existentes entre os dois períodos se faz presente, primordialmente, pelo fato de a caatinga ser uma vegetação que perde as suas folhas na época seca, o que deixa de ser classificada como vegetação densa e passa a ser caracterizada como vegetação escassa e/ou solo exposto.

Notam-se produtos do SAVI, exposto na Figura 6 para a bacia, para o período o seco e chuvoso do ano de 2022, respectivamente.

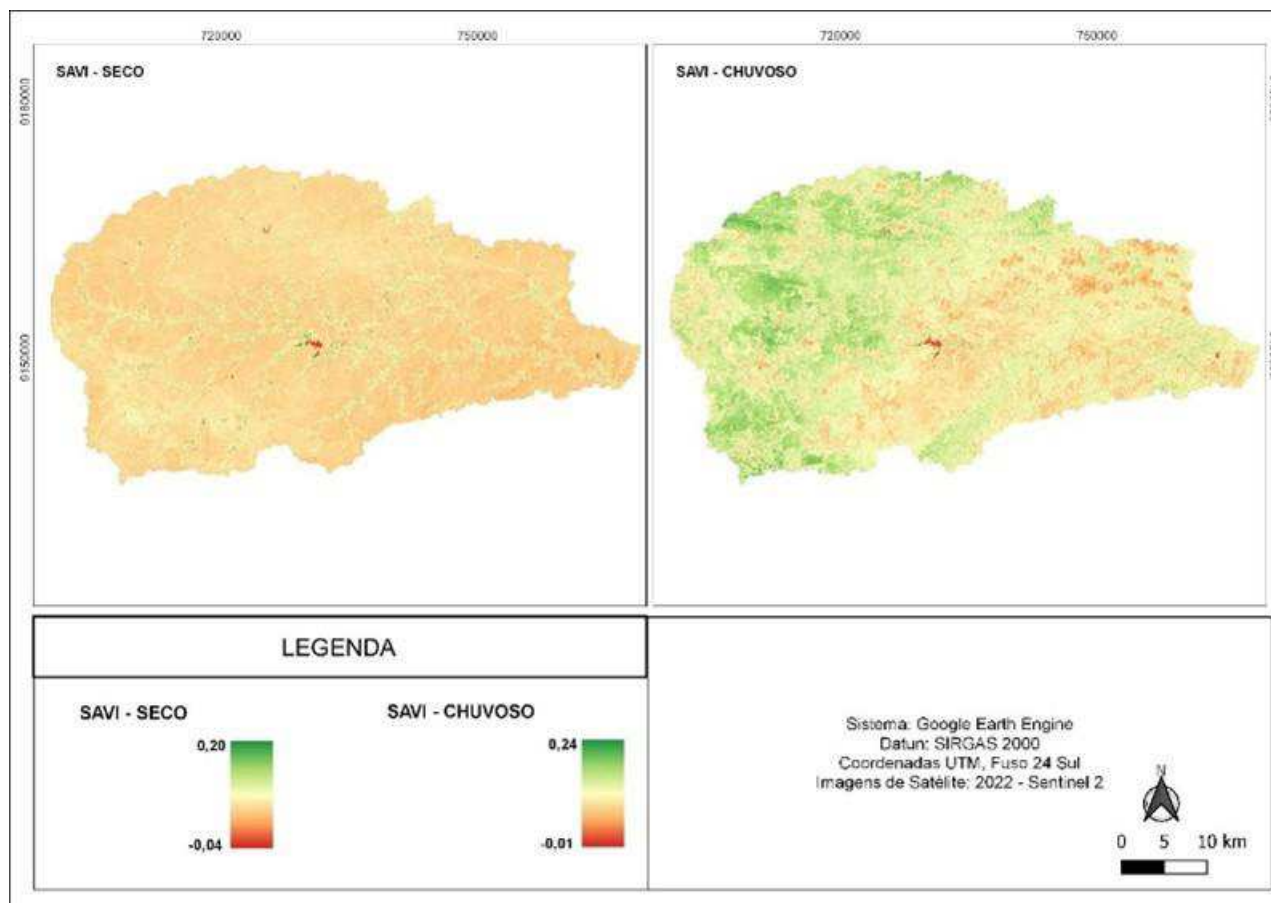


Figura 6. SAVI para o período seco e chuvoso do ano de 2022.

Fonte: Adaptado do Google Earth Engine (2023).

Rêgo et al. (2012) aponta que, o SAVI expressa valores que podem variar de $-1,0 \leq \text{SAVI} \leq 1,0$, sendo que valores positivos correspondem a vegetação mais densa, no entanto valores negativos representam solo exposto, corpos d'água ou área construída. Coincidindo com os valores apresentados por este trabalho, valores de máximo e mínimo do SAVI, para o período seco, $-0,04$ e $0,20$ (Figura 6), respectivamente, sendo caracterizada como solo exposto, corpos d'água ou área construída e vegetação mais densa na área em estudo.

Barbosa et al. (2021), utilizando geotecnologias aplicadas ao estudo da cobertura vegetal na região do presente estudo, os mesmos encontraram valores de SAVI na faixa de $-0,05 \leq \text{SAVI} \leq 0,4$ para o período seco estudado, o que está de acordo com os resultados obtidos no presente trabalho, que são $-0,04$ e $0,20$.

Miranda e Nascimento (2013) destacam que, o SAVI quando comparado ao NDVI, separa áreas de solo de áreas de vegetação e pondera pesos diferentes para cada uma dessas classes, tornando mais evidente e menos expressivo o efeito do solo. Silva e Galvêncio (2012), comparando a variação nos índices NDVI e SAVI no município de Petrolina-PE, destacaram a eficiência do SAVI, principalmente em as áreas mais densamente vegetadas, comprovando que este parâmetro possui confiabilidade para os períodos secos do semiárido. Rocha et al. (2011), concluíram que o SAVI discrimina melhor os alvos na superfície terrestre, apresentando um maior número de classes.

A escolha do SAVI foi baseada no critério deste índice ser um NDVI melhorado e ter um coeficiente de ajuste ao solo (ALHUMAIMA & ABDULLAEV, 2020; BAO et al., 2021). Resultados promissores com a aplicação de índices de vegetação como o SAVI são evidenciados na literatura contemporânea (CHAVES et al., 2020; CHAVES et al., 2021; PICOLI et al., 2020).

Conforme Silva e Galvêncio (2012), o SAVI é um índice que tem por finalidade amenizar os efeitos de background (interferência/ruído da refletividade). Para Ponzoni e Shimabukuro (2010), o SAVI constata que o brilho do solo, principalmente em tons escuros é aumentado os valores dos índices de vegetação, especialmente para níveis de cobertura vegetal com aproximadamente 50% de cobertura verde.

Na Figura 6, notam-se produtos de SAVI para a área de estudo no período chuvoso no ano de 2022, sendo atribuídos os valores de máximo e mínimo, -0,01 e 0,24, correspondendo a solo exposto, corpos d'água ou área construída e vegetação mais densa, respectivamente.

Em pesquisa realizada por Melo et al. (2022), o SAVI apresentou valor de -0,20 para o período chuvoso, indicando alta densidade de cobertura vegetal, portanto, apresentando um nível denso e médio de vegetação. Entretanto, Oliveira (2019) obteve valores de SAVI para o período chuvoso, variando de -

$0,76 \leq \text{SAVI} \leq 0,85$, em pesquisa voltada a análise da cobertura vegetal no município de Juazeirinho-PB, mediante o ano de 2010.

Para Melo et al. (2022), avaliando a dinâmica espaço-temporal da cobertura vegetal na mesorregião do Agreste do Estado de Pernambuco, por meio de índices de vegetação, adotaram $L = 0,5$, encontraram valores para o período chuvoso variando de um valor máximo de 0,80 a um valor mínimo de -0,20, mediante o índice de vegetação SAVI. Comportamento semelhante ao relatado por Bezerra et al. (2020), aplicando o $L = 0,5$, onde o SAVI variou entre $-0,44 \leq \text{SAVI} \leq 0,83$, para o período chuvoso.

Segundo Vani e Mandla (2017), o SAVI é um complemento ao NDVI, onde a vegetação e a cobertura florestal estão presentes na terra que são cobertos por vegetação com um pixel de até 15%. Mediante Ribeiro et al. (2016b) o uso do SAVI, no bioma Caatinga, é mais apropriado que os demais índices de vegetação, uma vez que, o mesmo corrige os efeitos do solo na resposta espectral.

Gameiro et al. (2016) apontam que, os dados de SAVI e NDVI se assemelham, diferenciando-se o fato de o SAVI possuir quantitativos mais significativos em relação as médias, além de contribuir para o destaque das características de regiões com presença ou ausência de vegetação, além dos corpos d'água. Devido à similaridade entre os resultados desses parâmetros, com o acréscimo do valor das classes no índice SAVI, os autores acrescentam que considerando o fato desse índice eliminar os efeitos do solo, isso contribui para que haja uma visão mais realista da situação da área analisada.

Santos et al. (2020), com o uso de geotecnologias no estudo da degradação ambiental na bacia hidrográfica do rio Sucuru, verificaram os níveis de degradação moderado, muito grave, grave, moderado grave, moderado, moderado baixo e baixo das terras. Os mesmos relataram que nas margens dos corpos hídricos da área de estudo, em sua maior parte, encontram-se no nível de degradação grave, decorrente da retirada dessa vegetação em função da

exploração dessas áreas para os mais variados usos. Os processos de degradação, aliados ao uso incorreto das terras da bacia estudada tiveram como principal consequência, o êxodo rural, necessitando da intervenção do poder público para que as comunidades locais possam desenvolver atividades sustentáveis, considerando aspectos sociais, econômicos e ambientais. Resultados esses enfatizados por Sousa et al. (2022), ao relatarem o crescimento das atividades florestais e pecuárias, na bacia hidrográfica do rio Sucuru.

ANÁLISE DOS ÍNDICES BIOFÍSICOS

No gráfico da Figura 7, pode-se verificar a média anual dos valores de NDVI entre 2001 à 2019. Observa-se que, a variação do NDVI durante o período oscila conforme a atividade vegetativa entre 2012 e 2017. O menor valor de NDVI apresenta-se em 2013, com 0,35, entretanto o maior valor é observado em 2009 de 0,57. Resultados similares foram encontrados por Bezerra (2018), onde ressalta um longo período de crescimento vegetativo em 2009, que coincidiu com eventos de forte La Niña nos anos de 2007-2008. Por outro lado, a quebra abrupta no crescimento da vegetação em 2012 não se mostra associada, de início, ao fenômeno de El Niño. Condição essa explanada nos estudos de Brito et al. (2021), no qual os autores utilizando dados do CHIRPS, apontaram que a intensificação da seca em 2012 estava relacionada ao Oceano Atlântico Norte anormalmente quente, o que favoreceu uma posição anormal ao norte da Zona de Convergência Intertropical (ZCIT), causando assim uma diminuição em chuvas.

Os valores de NDVI coincidem com o aumento da precipitação média anual da área de estudo, evidenciando uma rápida resposta do NDVI às chuvas. Bezerra (2018) salienta que, os altos valores de NDVI encontrados a partir dos períodos chuvosos indicam que as atuações de sistemas climáticos no Nordeste Brasileiro estão associadas ao aumento da variabilidade da vegetação, que é compreendida pela rápida resposta da vegetação de caatinga.

Cavalcante et al. (2020) relatam que, as diferenças de NDVI entre os períodos menos e mais chuvosos manifesta a relevância da disponibilidade de água como fator limitante da atividade fotossintética. Aquino et al. (2012) e Santos e Negri (1997), relatam a correlação do NDVI com variáveis climáticas tais como, a precipitação e a temperatura da superfície terrestre. As oscilações entre as estações seca e úmida durante o ano e entre os diferentes anos, com condições de maior ou menor secura, influenciam de forma direta o comportamento fenológico das plantas. Confirmado pelos resultados obtidos no NDVI.




Figura 7. Série temporal da média anual de NDVI.

Fonte: adaptado de Google Earth Engine (2023).

Os valores médios de LST ao longo dos anos (Figura 8), possuem valor mínimo e máximo de 32,11 e 36,68°C, respectivamente. O LST comporta-se de maneira semelhante aos outros parâmetros analisados nesta pesquisa. Esse comportamento é relacionado ao regime pluviométrico, solo exposto, baixa vegetação e ação antrópica. Tais condições podem contribuir com o aumento de temperatura na região. Resultados esses enfatizados por Sousa et al. (2022), ao relatarem o crescimento das atividades florestais e pecuárias, na bacia hidrográfica do rio Sucuru. Aires et al. (2021), relatam que as alterações na camada vegetal da superfície terrestre na cidade de Pau dos Ferros-RN, são decorrentes dos impactos das ações antrópica, contribuindo para os baixos valores de NDVI, bem como para a elevação de LST. Ideião (2009) analisando parâmetros biofísicos na bacia hidrográfica do rio Taperoá-PB, explana que a LST se destacou, pois possui uma ação determinante sobre o crescimento e o desenvolvimento das plantas, influenciando muitos processos físicos, químicos e biológicos, apresentando uma grande relevância no gerenciamento dos recursos naturais.




Figura 8. Série temporal da média anual de LST.

Fonte: adaptado de Google Earth Engine (2023).

Silva et al. (2023), avaliaram os padrões de mudança na temperatura de superfície terrestre (LST) nos principais domínios de vegetação do Brasil entre um período de 13 anos, observaram decréscimos de temperatura, para a âmbito Semiárido, entre os anos de 2004 à 2011. Os mesmos autores relatam que as variáveis biofísicas como LST e NDVI sofreram influência de padrões externos, como precipitação e déficit hídrico. Fernandes et al. (2015), relatam que desde o século XVII com os avanços da pecuária, a Caatinga vem passando por processos de exploração quanto ao uso da terra. Estudos recentes mostraram que em áreas do semiárido do Brasil, há aumento na LST quando esses ambientes são convertidos em domínios antrópicos com baixa (ou nula) densidade de biomassa (MARONEZE et al., 2014; PEREIRA et al., 2016).

O período de 2009 à 2011 apresentam valores de LST mais baixos, evidenciando uma maior densidade vegetativa (Figura 7), como também altos valores de precipitação média anual (Figura 9). Em contrapartida, entre os anos de 2012 à 2017, nota-se uma oscilação na LST da região, onde encontra-se os valores mais altos das séries temporais do LST. Souto et al. (2018) e Pires e Bueno (2015), relatam que tanto a vegetação como a temperatura da superfície são altamente relacionadas com variabilidade da água para a região, ou seja, com a precipitação. Conforme Souto et al. (2018), fatores locais que podem influenciar no aumento na temperatura é a falta de cobertura vegetal, que influencia nas condições de tempo vigente através da absorção direta e reflexão da radiação solar incidente.

Na Figura 9 observa-se o gráfico das médias anuais de precipitação na bacia em estudo, demonstrando valores mínimos e máximos de 41,52 e 78,25mm, respectivamente. Esse resultado confirma o entendimento do comportamento da vegetação e da temperatura na região. Entre 2012 e 2017, as médias de NDVI são menores e os valores de LST maiores, vale ressaltar que, este apresenta-se um período de menores valores de precipitação em comparação aos outros

períodos. O ano de 2009 proporciona as maiores reduções médias de NDVI e LST e os maiores valores médios anuais de precipitação nos 20 anos analisados.

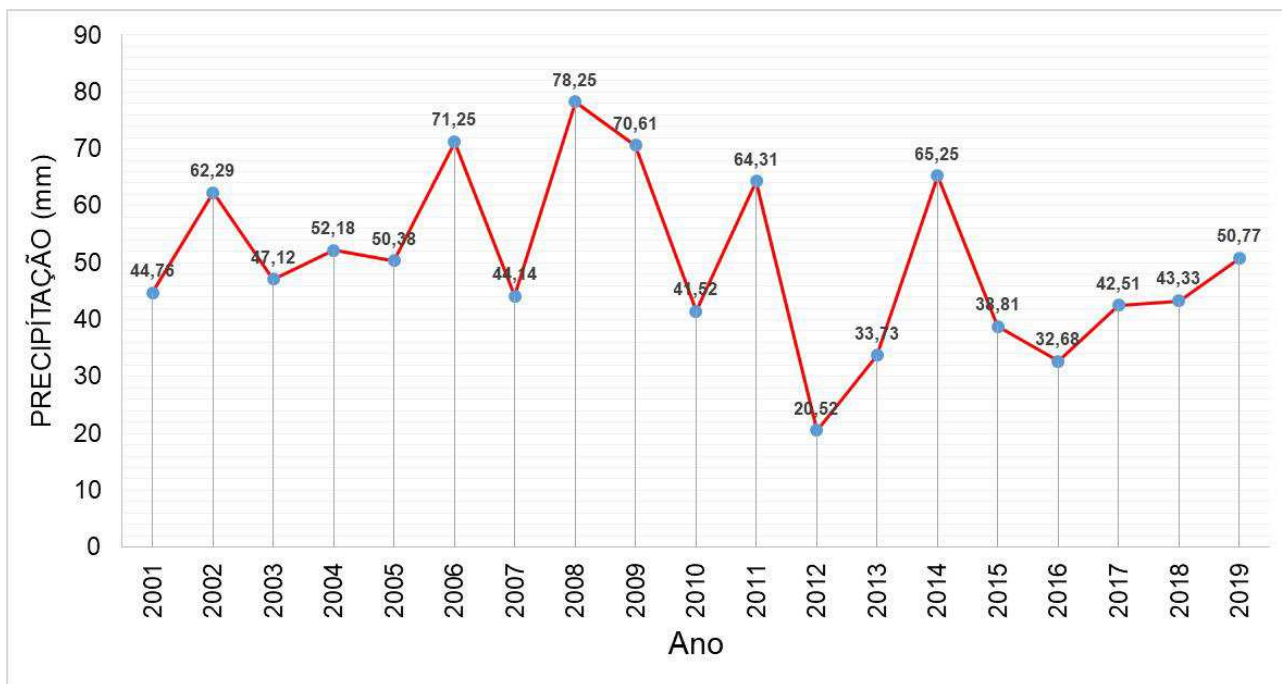


Figura 9. Série temporal da média anual de precipitação.

Fonte: adaptado de Google Earth Engine (2023).

De acordo com Sampaio (2003) e Costa (2014), o fator de maior influência no comportamento da vegetação, principalmente em regiões semiáridas, é representado pela precipitação, uma vez que, exerce importante papel na distribuição das espécies, produção de biomassa, configuração do relevo e condições edáficas. Santos et al. (2019), ao estudarem a precipitação média anual no Estado da Paraíba de 1998 à 2015 usando dados da Tropical Rainfall Measuring Mission (TRMM) e aplicando o teste de Mann-Kendall, observaram que o ano de 2012 foi o ano mais seco, com um valor médio de aproximadamente 400mm em toda a área de estudo. Os autores salientam ainda que, a seca ocorre com frequência no Estado da Paraíba, ocasionando em grandes perdas agrícolas e socioeconômicas (SANTOS et al., 2019).

De acordo com Bezerra (2018), a variação de anos chuvosos e secos no Nordeste Brasileiro são influenciados por sistemas atmosféricos dos oceanos Pacífico e Atlântico. Dentre os mecanismos responsáveis pela seca nessa região, destacam-se o El Niño e o fenômeno tropical anormalmente quente do Atlântico Norte, isoladamente ou em combinação (CUNHA et al., 2019; NOBRE et al., 2016; MARENGO et al., 2016; RODRIGUES & McPHADEN, 2014).




CONCLUSÃO

A aplicação bem-sucedida da computação em nuvem GEE foi crucial para mapear com êxito o uso e cobertura da terra na bacia hidrográfica do rio Sucuru. O GEE, conhecido por sua versatilidade, mostrou adaptabilidade através de suas capacidades integrativas e plataforma eficaz para desenvolvimento de scripts.

Para o classificador RF, identificou-se o melhor desempenho por meio de parâmetros estatísticos, Matriz de Confusão, Coeficiente Kappa, Acurácia Geral, Acurácia do Produtor e Acurácia do Usuário. A combinação do classificador RF com a abordagem RGB-Índices demonstrou excelente capacidade de distinguir classes e classificar o uso e cobertura da terra, resultando em menor confusão espectral e acurácia acima de 89,98%. A inclusão de índices espectrais contribuiu significativamente para alcançar níveis satisfatórios de precisão.

No processamento em nuvem digital do Google Earth Engine (GEE), houve eficiência na previsão de índices de vegetação, otimizando o tempo de processamento e minimizando erros com correções de refletância na superfície terrestre. Os resultados de NDVI e SAVI variaram no período seco e chuvoso, evidenciando características de pastagem, arbustos, vegetação densa, área construída e corpos d'água.

O GEE também se destacou ao processar imagens dos sensores MODIS e TerraClimate de maneira rápida e satisfatória, abrangendo todas as etapas necessárias. Observou-se forte influência da precipitação sobre NDVI e LST, com um aumento vegetativo entre 2007 e 2011, seguido de declínio em 2012, demonstrando a sensibilidade desses índices ao regime pluviométrico irregular ao longo dos anos.



REFERÊNCIAS BIBLIOGRÁFICAS

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. Campina Grande, 2008.

ALVES, T. L. B. Avaliação do nível de degradação das terras (desertificação) no alto curso da bacia hidrográfica do Rio Paraíba. 143f. Tese (Doutorado em

Recursos Naturais). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2016.

ABATZOGLOU, J. T.; DOBROWSKI, S. Z.; PARKS, S. A.; HEGEWISCH, K. C. TerraClimate, a high-resolution global dataset of monthly climate and climatic water balance from 1958–2015. *Scientific Data*, v.5, n.1, p.1-12, 2018.

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, 2021.

ANDRADE, J. M. Classificação da cobertura do solo da caatinga: avaliação de abordagens em Machine Learning utilizando dados Landsat mono e multi-temporais. 69f. Dissertação (Mestrado em Engenharia Civil e Ambiental). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2021.

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*. 2.a ed. CRC Press, 2012. p.533-548.

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.

ALHUMAIMA, A. S.; ABDULLAEV, S. M. Tigris basin landscapes: Sensitivity of vegetation index NDVI to climate variability derived from observational and reanalysis data. *Earth Interactions*, v.24, n.7, p.1-18, 2020.

AQUINO, C. M. S. D.; OLIVEIRA, J. G. B. D.; ALMEIDA, J. A. P. D. Análise da desertificação do núcleo de São Raimundo Nonato–Piauí. Análise da desertificação do núcleo de São Raimundo Nonato-Piauí. *Revista Brasileira de Cartografia*, n.64/3, p.287-299, 2012.

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.

AIRES, A. A.; BEZERRA, J. M. Mapeamento do índice de vegetação e temperatura de superfície da cidade de Pau dos Ferros-RN. *Revista Tecnologia e Sociedade*, v.17, n.48, p.113-131, 2021

BREIMAN, L. Random forests. *Machine Learning*, v.45, p.5-32, 2001.

BARBOSA, L. C.; BORGES, K.; FERREIRA, W. D. S.; TORRES, M. V. E.; SILVA, A. A. T. Variabilidade espaço-temporal da cobertura do solo por índices de vegetação e água no município de Santana do Araguaia-PA. In: Congresso Araguaense de Ciências Exatas, Tecnológica e Social Aplicada, 1, 2019, Pará. Anais...Pará, 2019.

BRITO, C. S.; SILVA, R. M.; SANTOS, C. A. G.; NETO, R. M. B.; COELHO, V. H. R. Monitoring meteorological drought in a semiarid region using two long-term satellite-estimated rainfall datasets: A case study of the Piranhas River basin, northeastern Brazil. *Atmospheric Research*, v.250, e105380, 2021.

BEZERRA, D. X. Variabilidade espaço-temporal do NDVI gerado a partir do satélite TERRA/MODIS sobre o Nordeste brasileiro. 76f. Trabalho de Conclusão de Curso (Graduação em Ciências Ambientais). Instituto de Ciências do Mar. Universidade Federal do Ceará. Fortaleza, 2018.

BEZERRA, A. C.; SILVA, J. L. B.; MOURA, G. B. A.; LOPES, P. M. O.; NASCIMENTO, C. R.; RIBEIRO, E. P.; GALVÍNCIO, J. D.; SILVA, M. V. Dynamics of land cover and land use in Pernambuco (Brazil): Spatio-temporal variability and temporal trends of biophysical parameters. *Remote Sensing Applications: Society and Environment*, v.25, e100677, 2022.

BAO, Z.; ZHANG, J.; WANG, G.; GUAN, T.; JIN, J.; LIU, Y.; LI, M.; MA, T. The sensitivity of vegetation cover to climate change in multiple climatic zones using machine learning algorithms. *Ecological Indicators*, v.124, e107443, 2021.

BECERRA, J. A. B.; SHIMABUKURO, Y. E.; ALVALÁ, R. C. S. Relação do padrão sazonal da vegetação com a precipitação na região de Cerrado da Amazônia Legal, usando índices espectrais de vegetação. *Revista Brasileira de Meteorologia*, v.24, n.2, p.125-134, 2009.

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.

BESALATPOUR, A. A.; AYOUBI, S.; HAJABBASI, M. A.; MOSADDEGHI, M. R.; SCHULIN, R. Estimating wet soil aggregate stability from easily available properties in a highly mountainous watershed. *Catena*, v.111, p.72-79, 2013.

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.

CUNHA, A. P. M.; ZERI, M.; DEUSDARÁ LEAL, K.; COSTA, L.; CUARTAS, L. A.; MARENGO, J. A.; TOMASELLA, J.; VIEIRA, R. M.; BARBOSA, A. A.; CUNNINGHAM, C.; CAL GARCIA, J. V.; BROEDEL, E.; ALVALÁ, R.; RIBEIRO-NETO, G. Extreme drought events over Brazil from 2011 to 2019. *Atmosphere*, v.10, n.11, e642, 2019.

COSTA, A. L. Determinação de parâmetros biofísicos na região de Araripina-Pernambuco com técnicas de sensoriamento remoto. 67f. Dissertação (Mestrado em Engenharia Agrícola). Departamento de Engenharia Agrícola. Universidade Federal Rural de Pernambuco. Recife, 2014.

CHAVES, M. E. D.; PICOLI, M. C. A.; SANCHES, I. D. Recent applications of LANDSAT 8/OLI and Sentinel-2/MSI for land use and land cover mapping: A systematic review. *Remote Sensing*, v.12, n.18, e3062, 2020.

CHAVES, M. E.; SOARES, A. R.; SANCHES, I. D.; FRONZA, J. G. CBERS data cubes for land use and land cover mapping in the Brazilian Cerrado agricultural belt. *International Journal of Remote Sensing*, v.42, n.21, p.8398-8432, 2021.

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, 2020. p.195-207.

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.

CAVALCANTE, J. C.; ALMEIDA, C. A.; CASTELO, T. B. Análise de NDVI e temperatura da superfície terrestre utilizando a plataforma do Google Earth Engine em área de savana amazônica e floresta secundária, no município de Vigia-PA. *Revista de Geociências do Nordeste*, v.6, n.1, p.64-70, 2020.

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

DASH, P.; GÖTTSCHE, F. M.; OLESEN, F. S.; FISCHER, H. Land surface temperature and emissivity estimation from passive sensor data: Theory and practice-current trends. *International Journal of Remote Sensing*, v.23, n.13, p.2563-2594, 2002.

DRUSCH, M.; DEL BELLO, U.; CARLIER, S.; COLIN, O.; FERNANDEZ, V.; GASCON, F.; HOERSCH, B.; ISOLA, C.; LABERINTI, P.; MARTIMORT, P.; MEYGRET, A.; SPOTO, F.; SY, O.; MARCHESE, F.; BARGELLINI, P. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sensing of Environment*, v.120, p.25-36, 2012.

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.

DENG, Y.; WANG, S.; BAI, X.; TIAN, Y.; WU, L.; XIAO, J.; CHEN, F.; QIAN, Q. Relationship among land surface temperature and LUCC, NDVI in typical karst area. *Scientific Reports*, v.8, n.641, p.1-12, 2018.

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.

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.

FERNANDES, M. R. D. M.; MATRICARDI, E. A. T.; ALMEIDA, A. Q. D.; FERNANDES, M. M. Mudanças do uso e de cobertura da terra na região semiárida de Sergipe. *Floresta e Ambiente*, v.22, p.472-482, 2015.

FERREIRA, E. M. Geoprocessamento aplicado ao monitoramento ambiental, texto: análise quantitativa de parâmetros biofísicos de bacia hidrográfica obtidos por Sensoriamento Remoto. *Revista Eletrônica de Engenharia Civil*, v.7, n.1, p.31-37, 2013.

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.

FREITAS, I. G. F.; ALVES, L. E. R.; GOMES, H. B.; JUNIOR, J. R. S.; SANTIAGO, D. B.; SILVA, R. A. Analysis of behavior of vegetation in the year of 2016 for the municipality of Remanso-BA. Revista Geama, v.3, n.3, p.149-156, 2017.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAN, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations - a new environmental record for monitoring extremes. Scientific Data, v.2, n.1, p.1-21, 2015.

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.

FERREIRA, B.; ZIMMERMANN, D. M.; CRISPIM, L. C.; FLASH, M. F.; VIEIRA, C. A. O. Análise sazonal das temperaturas superficiais do estado de Santa Catarina entre os anos de 2000 e 2010. In: Congresso Brasileiro de Cartografia e Expositiva, 27, 2015, Rio de Janeiro. Anais...Rio de Janeiro, 2017.

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.

GANDHI, M. G.; PARTHIBAN, S.; THUMMALU, N.; CHRISTY, A. NDVI: Vegetation change detection using remote sensing and GIS–A case study of Vellore District. *Procedia Computer Science*, v.57, p.1199-1210, 2015.

GAMEIRO, S.; TEIXEIRA, C. P. B; NETO, T. A. S.; LOPES, M. F. L.; DUARTE, C. R.; SOUTO, M. V. S; ZIMBACK, C. R. L. Avaliação da cobertura vegetal por meio de índices de vegetação (NDVI, SAVI e IAF) na sub-bacia hidrográfica do Baixo Jaguaribe, CE. *Terræ*, v.13, n.1-2, p.15-22, 2016.

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.

GORGANI, S. A.; PANAH, M.; REZAIE, F. The Relationship between NDVI and LST in the urban area of Mashhad, Iran. In: International Conference on Civil Engineering Architecture & Urban Sustainable Development, 1, 7, Iran. Anais...Iran, 2013.

GUNTER'S SPACE PAGE. Sentinel 2A, 2B, 2C, 2D. 2020. Disponível em: <https://space.skyrocket.de/doc_sdat/sentinel-2.htm>. Acesso em: 11 ago. 2023.

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.

HOROWITZ, F. G. MODIS daily land surface temperature estimates in Google Earth Engine as an aid in geothermal energy siting. In: World Geothermal Congress, 2015, Melbourne. Anais...Melbourne, 2015.

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.

IDEIÃO, S. M. A. Imagens Multiespectrais e Aplicações em Recursos Hídricos: Temperatura da Superfície e Balanços de Radiação e Energia. 156f. Dissertação (Mestrado em Engenharia Civil). Centro de Tecnologia e Recursos Naturais. Universidade Federal de Campina Grande. Campina Grande, 2009.

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

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.

KARABURUN, A. Estimation of C factor for soil erosion modeling using NDVI in Buyukcekmece watershed. *Ozean Journal of Applied Sciences*, v.3, n.1, p.77-85, 2010.

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.

LIMA, M. M. P. Uso de imagens Sentinel para estimativa do estoque de carbono e biomassa acima do solo no bioma Caatinga. 107f. Dissertação (Mestrado em Engenharia Agrícola). Universidade Federal do Ceará. Fortaleza, 2021.

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 BINBIN, L.; ZHANBIN, L.; TAO, Y.; PENG, L. Research on fractal dimension of vegetation cover based on normalized difference vegetation index in watershed scale. *Transactions of the Chinese Society of Agricultural Engineering*, v.30, n.15, p.239-247, 2014.

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.

MEDEIROS, R. L. B.; SOUSA, G. M.; FIGUEIREDO, C. F. V.; FORMIGA, A. C. S.; OLIVEIRA, F. F. D.; OLIVEIRA, P. A. T.; NASCIMENTO, R. R. A.; MONTEIRO, A. O.;

LEITE, A. C. N. Resposta espectral do comportamento do NDVI e NDWI diante de diferentes intensidades pluviométricas na cidade de Patos–PB. *Research, Society and Development*, v.11, n.3, e49811326819, 2022.

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.

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.

MOREIRA, N. L. W. A relação entre a expansão agrícola e os índices biofísicos: uma análise por meio do Google Earth Engine na Bacia Hidrográfica do Alto Parnaíba. 93f. Trabalho Conclusão do Curso (Graduação em Geografia). Centro de Filosofia e Ciências Humanas. Universidade Federal de Santa Catarina. Florianópolis, 2022.

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.

MIRANDA, J. R.; NASCIMENTO, C. R. Análise de índices espectrais na avaliação de terraceamento em pastagem cultivadas no norte de Minas Gerais. *Enciclopedia Biosfera*, v.9, n.17, p.128-141, 2013.

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.

MELO, M. V. N.; OLIVEIRA, M. E. G.; ALMEIDA, G. L. P.; GOMES, N. F.; MORALES, K. R. M.; SANTANA, T. C.; SILVA, P. C.; MORAES, A. S.; PANDORFI, H.; SILVA, M. V. Spatiotemporal characterization of land cover and degradation in the agreste region of Pernambuco, Brazil, using cloud geoprocessing on Google Earth Engine. *Remote Sensing Applications: Society and Environment*, v.26, e100756, 2022.

MALDONADO, F. D. Desenvolvimento e avaliação de uma metodologia de detecção de mudanças na cobertura vegetal do semi-árido. 311f. Tese

(Doutorado em Sensoriamento Remoto). Instituto Nacional de Pesquisa Espaciais. São José dos Campos, 2005.

MACEDO, C. E. S. Estimativa dos Índices de Vegetação NDVI e SAVI na Unidade de Conservação do Parque Estadual das Carnaúbas – CE com utilização de técnicas do Sensoriamento Remoto. 84f. Monografia (Graduação em Engenharia Ambiental). Centro de Tecnologia. Universidade Federal do Ceará. Fortaleza, 2019.

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.

MARENGO, J. A.; ESPINOZA, J. C.; RONCHAIL, J.; ALVES, L. M. Tropical South America east of the Andes. *Bulletin of the American Meteorological Society*, v.97, n.8, e185, 2016.

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.

NOBRE, C. A.; MARENGO, J. A.; SELUCHI, M. E.; CUARTAS, L. A.; ALVES, L. M. Some characteristics and impacts of the drought and water crisis in Southeastern

Brazil during 2014 and 2015. *Journal of Water Resource and Protection*, v.8, n.2, p.252-262, 2016.

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.

OLIVEIRA, E. M. Mineração do caulim como tendência à desertificação no Seridó paraibano. 182f. Tese (Doutorado em Desenvolvimento e Meio Ambiente). Centro de Filosofia e Ciências Humanas. Universidade Federal de Pernambuco. Recife, 2019.

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, 2017. p.102-119.

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.

MARONEZE, M. M.; ZEPKA, L. Q.; VIEIRA, J. G.; QUEIROZ, M. I.; JACOB-LOPES, E. A tecnologia de remoção de fósforo: Gerenciamento do elemento em resíduos industriais. *Revista Ambiente & Água*, v.9, p.445-458, 2014.

PATEL, N. N.; ANGIULI, E.; GAMBA, P.; GAUGHAN, A.; LISINI, G.; STEVENS, F. R.; TATEM, A. J.; TRIANNI, G. Multitemporal settlement and population mapping from Landsat using Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, v.35, p.199-208, 2015.

PIRES, E. G. Análise da temperatura de superfície do Estado do Tocantins a partir do uso de geotecnologias. *Revista Interface*, n.10, p.133-144, 2015.

PAREDES-TREJO, F. J.; BARBOSA, H. A.; KUMAR, T. L. Validating CHIRPS-based satellite precipitation estimates in Northeast Brazil. *Journal of Arid Environments*, v.139, p.26-40, 2017.

PIRES, G. F.; BUENO, F. P. Unidades de Conservação Brasileira: Desafios da gestão. *Fórum Ambiental da Alta Paulista*, v.11, n.1, p.146-151, 2015

PICOLI, M. C. A.; SIMOES, R.; CHAVES, M.; SANTOS, L. A.; SANCHEZ, A.; SOARES, A.; SANCHES, I. D.; FERREIRA, K. R.; QUEIROZ, G. R. CBERS data cube: a powerful technology for mapping and monitoring Brazilian biomes. *ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, v.3, p.533-539, 2020.

PONZONI, F. J.; SHIMABUKURO, Y. E. Sensoriamento Remoto no Estudo da Vegetação. Parêntese: São José dos Campos, 2010. 144p.

PEREIRA, C. C. C.; MARIANO, Z. F.; CABRAL, J. B. P. Avaliação da temperatura de superfície continental (TSC) e o uso da terra na bacia da usina hidrelétrica de barra dos coqueiros (GO), por meio do sensoriamento remoto. Revista Brasileira de Climatologia, v.8, p.361-376, 2016.

ROCHA, W. J. S. F.; BORGES, E. F.; VIGANÓ, H. A. Análise do desempenho dos Índices de Vegetação NDVI e SAVI a partir de imagem Aster. In: Simpósio Brasileiro de Sensoriamento Remoto, 15, 2011, Curitiba. Anais... Curitiba, 2011.

RAVANELLI, R.; NASCETTI, A.; CIRIGLIANO, R. V.; DI RICO, C.; LEUZZI, G.; MONTI, P.; CRESPI, M. Monitoring the impact of land cover change on surface urban heat island through Google Earth Engine: Proposal of a global methodology, first applications and problems. Remote Sensing, v.10, n.9, e1488, 2018.

RODRIGUES, R. R.; McPHADEN, M. J. Why did the 2011–2012 La Niña cause a severe drought in the Brazilian Northeast? Geophysical Research Letters, v.41, n.3, p.1012-1018, 2014.

RAO, K. K.; PATWARDHAN, S. K.; KULKARNI, A.; KAMALA, K.; SABADE, S. S.; KUMAR, K. K. Projected changes in mean and extreme precipitation indices over India using PRECIS. Global and Planetary Change, v.113, p.77-90, 2014.

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.

RÊGO, S. C. A.; LIMA, P. P. S.; LIMA, M. N. S.; MONTEIRO, T. R. R. Análise comparativa dos índices de vegetação NDVI e SAVI no município de São Domingos do Cariri-PB. *Revista Geonorte*, v.3, n.5, p.1217-1229, 2012.

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, 2016a.

RIBEIRO, G. A, SILVA, J. N. C; SILVA, J. B. Índice de Vegetação Ajustado ao Solo (IVAS): estado da arte e suas potencialidades. *Revista Brasileira de Geografia Física*, v.9, n.06, p.2054-2074, 2016b.

ROSA, M. R. Classificação do padrão de ocupação urbana de São Paulo utilizando aprendizagem de máquina e Sentinel 2. *Revista do Departamento de Geografia*, p.15-21, 2018.

SILVA, L. G.; GALVÍNCIO, J. D. Análise Comparativa da Variação nos Índices NDVI e SAVI no Sítio PELD-22, em Petrolina-PE, na Primeira Década do Século XXI. *Revista Brasileira de Geografia Física*, v.5, n.6, p.1446-1456, 2013.

SOUTO, J. I. O.; TRINDADE, A. R.; TAVARES, P. A.; BELTRÃO, F. E. S.; OLIVEIRA, R. Impactos antrópicos condicionantes na variação da temperatura do ar: um

estudo de caso na APA Triunfo do Xingu, Pará (2005-2015). In: Simpósio de Estudos e Pesquisas em Ciências Ambientais na Amazônia, 7, 2018, Belém. Anais...Belém, 2018.

SAMPAIO, E. V. S. B. Caracterização da caatinga e fatores ambientes que afetam a ecologia das plantas lenhosas. *Ecosistemas brasileiros: manejo e conservação*. Fortaleza: Expressão Gráfica e Editora, p.129-142, 2003.

SOUSA, J. H. S. Aplicação do algoritmo Random Forest para classificação do uso e cobertura da terra na Bacia Hidrográfica do Rio Sucuru utilizando o Google Earth Engine. Monografia (Bacharelado em Engenharia de Biosistemas). Centro de Desenvolvimento Sustentável do Semiárido. Universidade Federal de Campina Grande. Sumé, 2023.

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.

SANTOS, P.; NEGRI, A. J. A comparison of the normalized difference vegetation index and rainfall for the Amazon and Northeastern Brazil. *Journal of Applied Meteorology and Climatology*, v.36, n.7, p.958-965, 1997.

SANTOS, C. A. G.; BRASIL NETO, R. M.; SILVA, R. M.; SANTOS, D. C. Innovative approach for geospatial drought severity classification: a case study of Paraíba state, Brazil. *Stochastic Environmental Research and Risk Assessment*, v.33, n.2, p.545-562, 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.

SILVA, L. A. P.; ROCHA, A. M.; SOUZA, C. M. P.; LEITE, M. E. Análise da temperatura de superfície terrestre e variáveis biofísicas em domínios de vegetação do Brasil. *Revista do Departamento de Geografia*, v.43, e181068, 2023.

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, 2020a.

SILVA, M. V.; PANDORFI, H.; LOPES, P. M. O.; SILVA, J. L. B.; ALMEIDA, G. L. P.; SILVA, D. A. D. O.; SANTOS, A.; RODRIGUES, J. A. D. M.; BATISTA, P. H. D.; JARDIM, A. M. D. R. F. Pilot monitoring of caatinga spatial-temporal dynamics through the action of agriculture and livestock in the brazilian semiarid. *Remote Sensing Applications: Society and Environment*, v.19, e100353, 2020b.

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.

ESA. The European Space Agency. Sentinel Online. 2021. Disponível em: <<https://sentinel.esa.int/web/sentinel/home>>. Acesso em: 11 ago. 2023.

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.

VALOR, E.; CASELLES, V. Mapping land surface emissivity from NDVI: Application to European, African, and South American areas. *Remote Sensing of Environment*, v.57, n.3, p.167-184, 1996.

VANI, V.; MANDLA, V. R. Comparative study of NDVI and SAVI vegetation indices in Anantapur district semi-arid areas. *Int. J. Civ. Eng. Technol*, v.8, n.4, p.559-566, 2017.

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. *Giscience & 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.

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.

YANG, X.; TANG, J.; MUSTARD, J. F. Beyond leaf color: Comparing camera-based phenological metrics with leaf biochemical, biophysical, and spectral properties throughout the growing season of a temperate deciduous forest. *Journal of Geophysical Research: Biogeosciences*, v.119, n.3, p.181-191, 2014.

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.



CURRICULUM DOS AUTORES


José Hugo Simplicio de Sousa: Graduando em Engenharia de Biosistemas na Universidade Federal de Campina Grande, CDSA/Campus Sumé com ênfase em Sensoriamento Remoto e geoprocessamento. Atuou como bolsista do Programa Institucional de Iniciação Científica-PIBIC, em projetos na área de Sensoriamento Remoto e Geoprocessamento, entre 2021 a 2023 e atuou em projeto na área de secagem de alimentos entre 2020 e 2021. Ex-Membro Associado Consultor Júnior da SistemBIO Jr, Empresa Júnior do curso de Engenharia de Biosistemas da UFCG/CDSA.

jose.hugo@estudante.ufcg.edu.br

 <https://orcid.org/0000-0001-5068-0663>

George do Nascimento Ribeiro: Possui graduação em Agronomia (2003) e mestrado em Manejo e Conservação de Solo e Água (2006) pela Universidade Federal da Paraíba, doutorado em Engenharia Agrícola pela Universidade Federal de Campina Grande (2014) e Pós-doutorado em Fontes Alternativas de Energias pelo Programa de Pós-graduação em Engenharia Química da UFCG (LABFREN/UFCG). Atualmente é professor da Universidade Federal de Campina Grande/CDSA/Campus Sumé. Tem experiência nas áreas de Geociências, com ênfase em Sensoriamento Remoto (recursos naturais, geotecnologias e mapeamento temático) e em Energias Renováveis (produção de hidrogênio como fonte de combustível para fuel cell e energia solar - placas fotovoltaicas).

george@ufcg.edu.br

 <https://orcid.org/0000-0003-4225-0967>

Paulo Roberto Megna Francisco: Atuou como Pesquisador de Desenvolvimento Científico Regional de Interiorização na Universidade Federal da Paraíba-UFPB-CCA/Areia. Graduado como Engenharia Agrícola pela UFCG. Doutorando em Recursos Naturais (Concentração em Engenharia de Recursos Naturais). Possui Doutorado em Engenharia Agrícola (Concentração em Irrigação e Drenagem) pela Universidade Federal de Campina Grande - UFCG (2013), Mestrado em Agronomia - Manejo de Solo e Água (Concentração - Agricultura Sustentável e Planejamento Ambiental) pela Universidade Federal da Paraíba - UFPB - Areia (2010) e também Graduado como Tecnólogo Agrícola (Mecanização) pela Universidade Estadual Paulista Júlio de Mesquita Filho - UNESP - Bauru (1990). Tem experiência na Docência na área de Agronomia, com ênfase em Mecanização Agrícola, Máquinas e Implementos Agrícolas e Máquinas Agrozootécnicas. Atua como pesquisador, colaborador e orientador em projetos junto à UFPB Campus de Areia, UFCG - Campus de Campina Grande, Campus de Sumé e Campus Patos. Tem experiência em classificação técnica e mapeamento de solos, aptidão agrícola e pedoclimática, capacidade de uso do solo, geoprocessamento, cartografia, sensoriamento remoto, geoestatística, geração de balanço hídrico e índices climáticos. Prestou consultoria para o INCRA/PB na realização de PDAs. Foi Consultor Ad hoc do CONFEA como organizador do CONTECC. Editor Chefe da Editora Portal Tecnológico-EPTEC. Atualmente colabora como organizador e na comissão científica do CNMA-Poços de Caldas.

paulomegna@gmail.com

 <https://orcid.org/0000-0002-5062-5434>


Paulo da Costa Medeiros: Possui graduação em Engenharia Civil pela Universidade Federal da Paraíba - Campus II (1995), mestrado em Pós Graduação em Engenharia Civil pela Universidade Federal da Paraíba - Campus II (1997) e doutorado em Recursos Naturais pela Universidade Federal de Campina Grande (2011). Atualmente é Associado II da Universidade Federal de Campina Grande. Tem experiência na área de Engenharia Civil, com ênfase em Engenharia Hidráulica. Atuando principalmente nos seguintes temas: Transformada de Wavelet Contínua, Hidrograma, gestão de recursos hídricos.

paulo.costa@professor.ufcg.edu.br

 <https://orcid.org/0000-0002-3506-2266>


João Miguel de Moraes Neto: Possui mestrado em Engenharia Agrícola pela Universidade Federal da Paraíba (1995) e doutorado em Recursos Naturais pela Universidade Federal da Paraíba (2003). Atualmente é professor titular da Universidade Federal de Campina Grande. Tem experiência na área de Engenharia Agrícola, com ênfase em Sensoriamento Remoto, atuando principalmente nos seguintes temas: degradação ambiental, geoprocessamento, desertificação, desastres naturais.

j.miguel.moraes@hotmail.com

 <https://orcid.org/0000-0001-7672-5540>



 **Eptec**
editora portal tecnológico



978-65-00-77715-4