



Recebido: 23/09/2023 | Revisado: 28/02/2024 | Aceito: 13/03/2024 | Publicado: 29/05/2024



This work is licensed under a Creative Commons Attribution 4.0 Unported License.

DOI: 10.31416/rsdv.v12i2.683

Aplicação de geotecnologias no uso e cobertura da terra na bacia hidrográfica do Alto Curso do rio Paraíba

Application of geotechnologies to land use and land cover in the Upper Paraíba River basin

SOUSA, José Hugo Simplicio de. Mestrando em Engenharia Agrícola

Universidade Federal de Campina Grande - Centro de Tecnologia e Recursos Naturais. CEP: 58429-900 / Telefone: (88) 98134-0293 / E-mail: hugosimplicio123@gmail.com ORCID: <http://orcid.org/0000-0001-5068-0663>

RIBEIRO, George do Nascimento. Doutor em Engenharia Agrícola e Docente da Unidade Acadêmica de Engenharia de Biotecnologia. Universidade Federal de Campina Grande - Centro de Desenvolvimento Sustentável do Semiárido. CEP: 58540-000 / Telefone: (83) 98613-4239 / E-mail: george@ufcg.edu.br ORCID: <http://orcid.org/0000-0003-4225-0967>

FRANCISCO, Paulo Roberto Megna. Doutor em Engenharia Agrícola

Universidade Federal de Campina Grande - Centro de Tecnologia e Recursos Naturais. CEP: 58429-900 / Telefone: (83) 99645-9950 / E-mail: paulomegna@gmail.com ORCID: <http://orcid.org/0000-0002-5062-5434>

CARVALHO, Wesley dos Santos. Doutorando em Ciências Ambientais e Sustentabilidade Agropecuária

Universidade Católica Dom Bosco - Centro Integrado de Proteção e Pesquisa Ambiental. CEP: 79117-900 / Telefone: (67) 99163-2534 / E-mail: wesleysc352@gmail.com ORCID: <http://orcid.org/0000-0003-1244-893X>

RESUMO

Através das atividades humanas impróprias no decorrer dos anos na bacia hidrográfica do Alto Curso do rio Paraíba, têm ocorrido transformações significativas em seu ecossistema. Os mapas que retratam a distribuição das atividades e tipos de cobertura da terra se tornaram ferramentas essenciais para fornecer dados exatos no processo de gerir as bacias hidrográficas. Com a chegada das plataformas de computação em nuvem e avanços nos classificadores de aprendizado de máquina, novas saídas estão aparecendo para a classificação mais precisa e de ampla escala dos usos e coberturas da terra. Este estudo buscou alcançar uma classificação precisa dos padrões de uso e cobertura da terra (LULC) na área da bacia analisada, no ano de 2021, por meio dos classificadores Classification and Regression Trees (CART), Random Forest (RF) e Minimum Distance - Euclidean (MMD). Para avaliar os resultados foram utilizadas as métricas como Índice Kappa, Acurácia Geral, Acurácia do Produtor e do Usuário. A plataforma de computação em nuvem do Google Earth Engine (GEE) para a criação e avaliação dos mapas de LULC acarretou um produto eficaz e ágil. O classificador RF se sobressaiu ao distinguir as várias classes com uma elevada precisão, obtendo uma interferência espectral reduzida e uma acurácia superior a 85%.

Palavras-chave: Caatinga, Cobertura vegetal, Sentinel-2.

ABSTRACT

Through improper human activities over the years in the Upper Paraíba River basin, there have been significant transformations in its ecosystem. Maps depicting the distribution of activities and types of land cover have become essential tools for providing accurate data in the process of managing river basins. With the arrival of cloud computing platforms and advances in machine learning



classifiers, new outlets are appearing for more accurate, large-scale classification of land uses and covers. This study sought to achieve an accurate classification of land use and land cover (LULC) patterns in the analyzed basin area in 2021, using the Classification and Regression Trees (CART), Random Forest (RF) and Minimum Distance - Euclidean (MMD) classifiers. Metrics such as Kappa Index, Overall Accuracy, Producer Accuracy and User Accuracy were used to evaluate the results. The Google Earth Engine (GEE) cloud computing platform for creating and evaluating LULC maps resulted in an effective and agile product. The RF classifier excelled in distinguishing the various classes with high precision, obtaining reduced spectral interference and an accuracy of over 85%.

keywords: Caatinga, Vegetation cover, Sentinel-2.

Introdução

Uma bacia hidrográfica está inter-relacionada aos diversos componentes da paisagem (geologia, geomorfologia, climatologia, hidrologia, uso da terra, etc). Assim, a utilização de seus recursos sem planejamento ambiental adequado terá como consequência a ocorrência de problemáticas econômicas e socioambientais existentes em diversos compartimentos ao longo da bacia hidrográfica (SOUSA e NASCIMENTO, 2015; SARAIVA-MAIA et al., 2024).

O estudo da mudança de uso e cobertura da terra chamado em inglês de *Land Use and Land Cover* (LULC) contribui para o planejamento e a utilização racional dos recursos da terra, podendo fornecer uma base científica para o desenvolvimento coordenado e sustentável da economia regional e do ambiente natural (CUI et al., 2022). Detectar alterações de LULC podem identificar potenciais eventos ambientais associados à rápida urbanização, conversão florestal e expansão agrícola, essas mudanças são indicadores de alterações que podem causar uma perda de biodiversidade e degradação do ambiente. A avaliação e o monitoramento da mudança LULC são essenciais para a criação de estratégias integradas de gestão de recursos hídricos e terrestres (ZURQANI et al., 2018).

As informações de classificação de uso e cobertura do solo podem ser obtidas a partir de imagens de satélite através do processo de interpretação e classificação de raster multibanda. A classificação de imagens (supervisionadas ou não supervisionadas) destina-se a uma categorização automática dos pixels do raster em classes pré-definidas (ALAM et al., 2020). Existem várias técnicas de classificação na literatura que podem ser aplicadas a imagens de sensoriamento remoto (LU e WENG, 2007; KHATAMI et al., 2016). De acordo com Yu et al. (2014), Maximum Likelihood Classifier (MLC), tem sido a técnica mais popular para classificação de imagens. No entanto, nos últimos tempos, os classificadores não paramétricos de aprendizado de máquina (ML) têm sido relatados como capazes de obter melhores resultados de classificação para LULC (GHIMIRE et al., 2012). Entre esses classificadores, o *Random Forest* (RF), o *Classification and Regression Trees* (CART) e o *Minimum Distance - Euclidean* (MMD) demonstraram obter resultados de classificação de LULC altamente precisos (FOODY e MATHUR, 2004; ADAM et al., 2014; YU et al., 2014; MAXWELL et al., 2018).

O CART é um classificador baseado em árvores de decisão binária simples divide recursivamente os nós até que um limite predefinido seja atingido, tem sido usado no mapeamento global de LULC (FRIEDL et al., 2002; MATHER e TSO, 2009). A precisão da classificação do CART e



seu rápido desempenho fazem dele um dos classificadores de LULC amplamente usados, embora tenha uma tendência comprovada de ajuste excessivo (LAWRENCE e WRIGHT, 2001).

Esse desafio pode ser enfrentado com sucesso pelo classificador RF desenvolvido por Breiman (2001). O RF é um algoritmo de aprendizado de máquina de conjunto não paramétrico amplamente aplicado em estudo ambientais. É um método de aprendizagem de conjunto baseado em uma árvore de decisão, que combina com regressão massiva de conjuntos e árvores de classificação. O usuário define o número de árvores de decisão em que um subconjunto de dados é extraído aleatoriamente das amostras de treinamento por meio de substituição para a construção de uma árvore, e as amostras não rotuladas são classificadas independentemente por cada árvore para chegar a uma decisão coletiva por meio de votação majoritária. Essa implementação intuitiva e seus resultados de alta precisão são os motivos pelos quais o RF é um dos classificadores de LULC favoritos (BREIMAN, 2001; GISLASON et al., 2006; TALUKDAR et al., 2020).

O MMD, por outro lado, segue uma abordagem de classificação diferente: ele classifica conjuntos de dados de imagens em classes que reduzem a distância entre a classe no espaço de vários recursos e os dados de imagem. Essa distância entre os dados de imagem é expressa como um índice de similaridade, de modo que a distância mínima e a maior similaridade sejam equivalentes. A ideia principal por trás desse processo é calcular a distância espectral entre o vetor de medição do pixel candidato e o vetor médio de cada assinatura (MURTAZA e ROMSHOO, 2014).

Para processar a grande quantidade de dados de sensoriamento remoto disponíveis atualmente as plataformas baseadas em nuvem, como o Google Earth Engine (GEE) oferecem recursos computacionais sem precedentes que nos permitem realizar análises geoespaciais em escala global (GORELICK et al., 2017). Muitos estudos aproveitaram o poder do GEE para a análise global de LULC. Por exemplo, o mapa global de mudança de cobertura florestal desenvolvido por Hansen et al. (2013), com resolução de 30 m usou dados de satélite multitemporais de 12 anos na GEE. Além disso, muitos estudos sobre urbanização (PATEL et al., 2015; GOLDBLATT et al., 2016), setor agrícola (DONG et al., 2016; SHELESTOV et al., 2017; AGUILAR et al., 2018; BECKER et al., 2021) e mapeamento digital do solo (PADARIAN et al., 2015), também utilizaram a GEE e seus classificadores de Machine Learning incorporados para o processamento de dados grandes e mais rápidos. Assim, os mapeamentos de LULC escala regional são de grande importância para a região semiárida brasileira, pois permitirá o monitoramento de mudanças na paisagem, a preservação da vegetação nativa, o planejamento e gestão dos recursos naturais, além de fomentar a realização de estudos científicos na região.

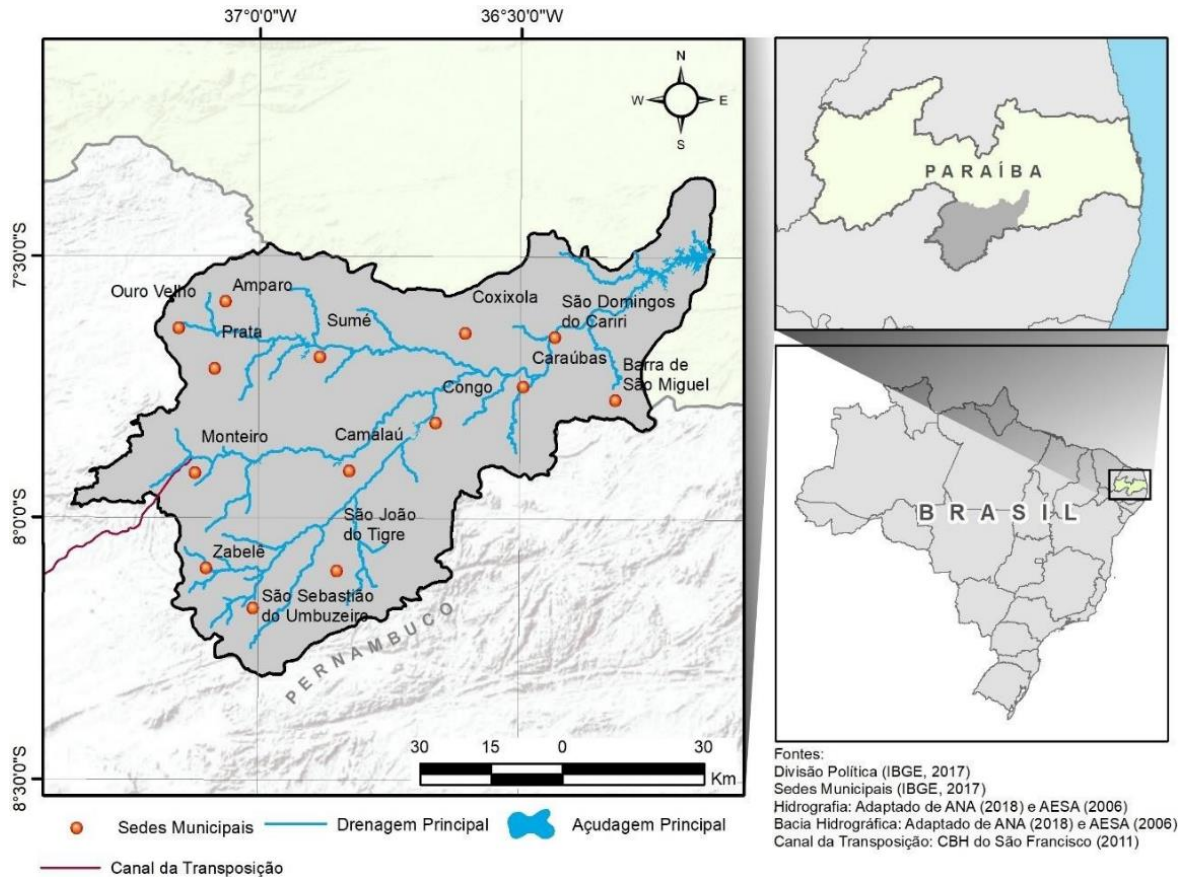
Desta forma, o objetivo principal deste trabalho é classificar o uso e cobertura da terra por meio da plataforma GEE na bacia hidrográfica do Alto Curso do rio Paraíba, utilizando-se imagens de satélite Sentinel-2 do ano de 2021 utilizando os algoritmos Classification and Regression Trees (CART), Random Forest (RF) e Minimum Distance - Euclidean (MMD).

Metodologia

A área de estudo abrange a bacia hidrográfica do Alto Curso do rio Paraíba, localizada na porção sul do Estado da Paraíba, na divisa com o Estado de Pernambuco, na região Nordeste do

Brasil. A bacia hidrográfica abrange uma área de aproximadamente 6.696,17 km². (FURTADO e SOUZA, 2016).

Figura 1. Localização da área de estudo.



Fonte: Brito et al. (2022).

O processamento de dados ocorreu no *Code Editor* do GEE, usando um script em *JavaScript*. A etapa inicial de mapeamento do LULC envolveu delimitar a área de interesse no GEE, utilizando dados vetoriais externos e as ferramentas de interface do GEE para selecionar a área sobre os planos de informação básica. Para este trabalho, a área de estudo foi sobreposta à cena da órbita 24MYS do Satélite Sentinel-2. Foram aplicados filtros nos metadados das imagens para remover áreas com excesso de cobertura de nuvens, mantendo um limite de cobertura de nuvens inferior a 1% na imagem. Para a composição da imagem final representativa, foram utilizadas todas as imagens Sentinel-2, disponíveis após a filtragem de nuvem entre 01-Jan-2021 a 31-Dez-2021. Desta forma o conjunto de imagens foi reduzida a uma única imagem representativa, através de uma operação de mediana entre todas as camadas, por meio do comando `“ee.ImageCollection().median()”`.

Neste estudo, utilizou-se os classificadores Classification and Regression Trees (CART), Random Forest (RF) e Minimum Distance - Euclidean (MMD). As técnicas `“ee.Classifier.smileCart”`, `“ee.Classifier.smileRandomForest”` e `“ee.Classifier.minimumDistance”`, foram respectivamente utilizadas para representar cada algoritmo, todos disponíveis no GEE.

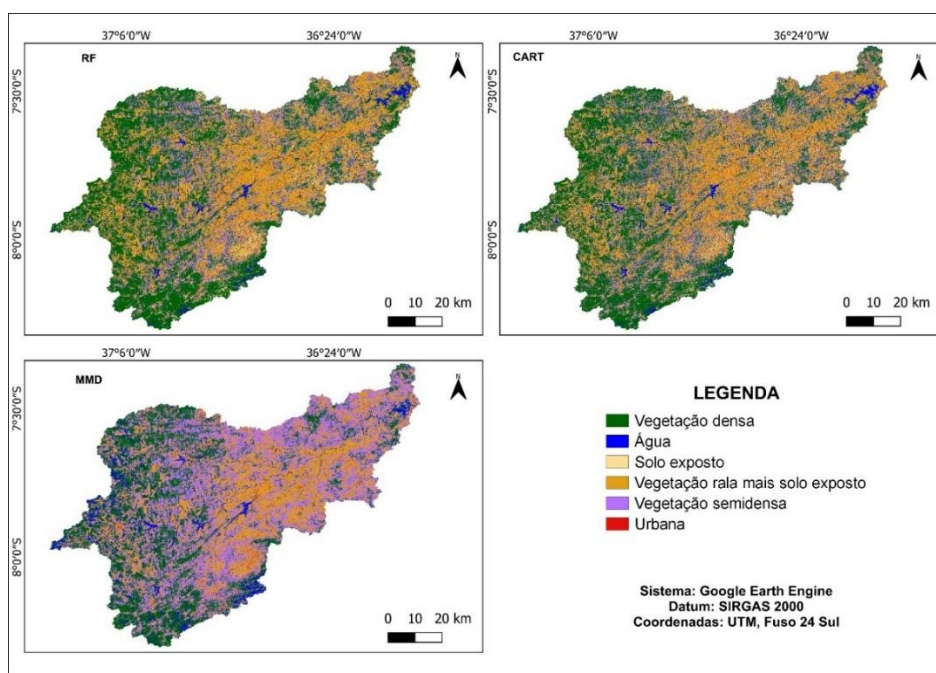


Neste trabalho, o total de amostras coletadas foram de 42.283, onde 70% das quais foram selecionadas aleatoriamente como participantes da classificação de LULC como amostras de treinamento e 30% usadas para verificar os resultados da classificação como amostras de validação, como sugerido por Zhang e Zhang, (2020). As classes de LULC inclui vegetação densa (essas áreas são caracterizadas por uma grande diversidade de plantas, árvores e arbustos, formando um dossel fechado que proporciona habitat para uma variedade de fauna nativa), água (representa corpos de água, como rios, lagos, lagoas, córregos e reservatórios), solo exposto (áreas onde o solo está diretamente exposto à superfície, sem cobertura vegetal significativa), vegetação rala mais solo exposto (áreas onde a vegetação é escassa ou fragmentada, geralmente devido à atividade agrícola ou pecuária extensiva. Pode incluir pastagens, campos de cultivo ou áreas degradadas pela agricultura intensiva), vegetação semidensa (áreas onde a densidade das plantas não é tão alta quanto na vegetação densa, mas também não é tão baixa quanto na vegetação rala. Isso significa que há uma presença significativa de árvores, arbustos e/ou vegetação herbácea, mas com espaços entre elas, permitindo uma certa permeabilidade visual e uma maior exposição do solo em comparação com a vegetação densa. Essa vegetação pode ser encontrada em áreas que foram parcialmente desmatadas ou onde ocorreu algum tipo de manejo florestal ou agropecuário) e urbana (refere-se a áreas urbanizadas, onde predominam edifícios, estradas, infraestrutura urbana e áreas residenciais e comerciais. Essas áreas são densamente povoadas e altamente desenvolvidas, com pouca ou nenhuma cobertura vegetal natural).

Após definir as classes de LULC como entrada no modelo, o próximo passo envolveu o processo de classificação executado por uma função na interface do GEE que considera as variáveis pré-estabelecidas. As amostras de validação independentes foram empregadas para avaliar a precisão dos classificadores, tendo como ponto de partida, a construção da Matriz de Confusão. Posteriormente, o Índice Kappa (I.K), Acurácia Geral (A.G), Acurácia do Produtor (A.P) e Acurácia do Usuário (A.U) foram calculados por meio do GEE.

Resultados e discussões

Quanto aos seis conjuntos de amostras, os pixels se encontram distribuídos nas classes de vegetação densa, vegetação semidensa, vegetação rala combinada com solo exposto, solo exposto, corpos hídricos e área urbana (Figura 2).

Figura 2. Mapas de LULC referente aos classificadores.


Fonte: Autores (2024).

Após a etapa de classificação, o subsequente passo consistiu na obtenção das superfícies relativas a cada categoria, conforme a Tabela 1. As dimensões referentes às seis classes foram computadas, considerando a total abrangência da classificação abarcando a bacia hidrográfica do Alto Curso do rio Paraíba. De acordo com os dados apresentados na Tabela 1, pode-se constatar que a classe vegetação densa ocupa 40,72% da extensão total, seguida pela classe vegetação rala combinada com solo exposto (31,85%), vegetação semidensa (18,98%), solo exposto (4,84%), área urbana (1,73%) e corpos hídricos (1,88%), obtidos por meio do algoritmo RF.

Tabela 1. Dados e índices das imagens produto.

Classificador	CART		RF		MMD	
	Área (ha)	(%)	Área (ha)	(%)	Área (ha)	(%)
VD	269.902,59	39,48	278.424,42	40,72	183.570,27	26,85
A	15.590,26	2,28	12.846,07	1,88	33.087,50	4,84
SE	46.588,86	6,81	33.114,83	4,84	1.414,80	0,21
VRMSE	195.547,19	28,60	217.780,50	31,85	185.953,80	27,20
VS	139.280,41	20,37	129.745,96	18,98	269.931,50	39,48
UR	16.813,35	2,46	11.810,88	1,73	9.764,80	1,43
Total	683.722,66	100,00	683.722,66	100,00	683.722,66	100,00
A.G	81,50		86,08		72,23	
I.K	75,86		81,80		64,86	

Legenda: VD = Vegetação densa; A = Água; SE = Solo Exposto; VRMSE = Vegetação rala mais solo exposto; VS = Vegetação semidensa; UR = Urbana; A.G = Acurácia Geral; I.K = Índice Kappa. Fonte: Adaptado de Sousa (2023).



Para aprimorar a avaliação da classificação, conforme sugerido por Stehman e Foody (2019), foram empregados os índices Kappa, Acurácia Geral, Acurácia do Produtor e Usuário, como realizados neste estudo. A precisão de 85% é normalmente considerada para aplicações em estudos de classificação de LULC (SCEPAN, 1999). Com isso o classificador que apresenta o melhor desempenho é o RF, com os valores de Acurácia Geral de 86,08% e Índice Kappa com 81,80%.

Resultados exposto por Arpitha et al. (2023), explanam a precisão de classificação do algoritmo RF aos demais classificadores, ao utilizarem a plataforma do GEE, para estudarem o LULC no Estado de Karnataka, Índia, o classificador RF apresentou os maiores valores de Índice Kappa 0,89, o CART apresentou um dos piores desempenho com Índice Kappa 0,71 e Acurácia Geral 84,62%.

O classificador CART apresenta uma classificação razoável, mediante a área de estudo. No entanto, o classificador MMD apresenta os menores valores de Acurácia Geral (72,23%) e Índice Kappa (64,86%) com precisão inferior a 85%. Apresentando erros de omissão, entre as classes, dentre todas as classes, ou seja, classes que foram incorretamente mapeadas pelo classificador.

Ao analisar os resultados apresentados na Tabela 2, observa-se que algumas das classes apresentam valores de Acurácia do Usuário (A.U) ou Acurácia do Produtor (A.P) inferiores a 60%. Isso indica que, o classificador demonstra uma qualidade inconsistente, refletindo a inadequada associação dos pixels com as amostras de treinamento em diversas classes. Isso também sugere que as amostras de treinamento são inadequadamente representativas para ambos os métodos (CARVALHO et al., 2021; SANTANA, 2021).

Tabela 2. Acurácia do Produtor e do Usuário.

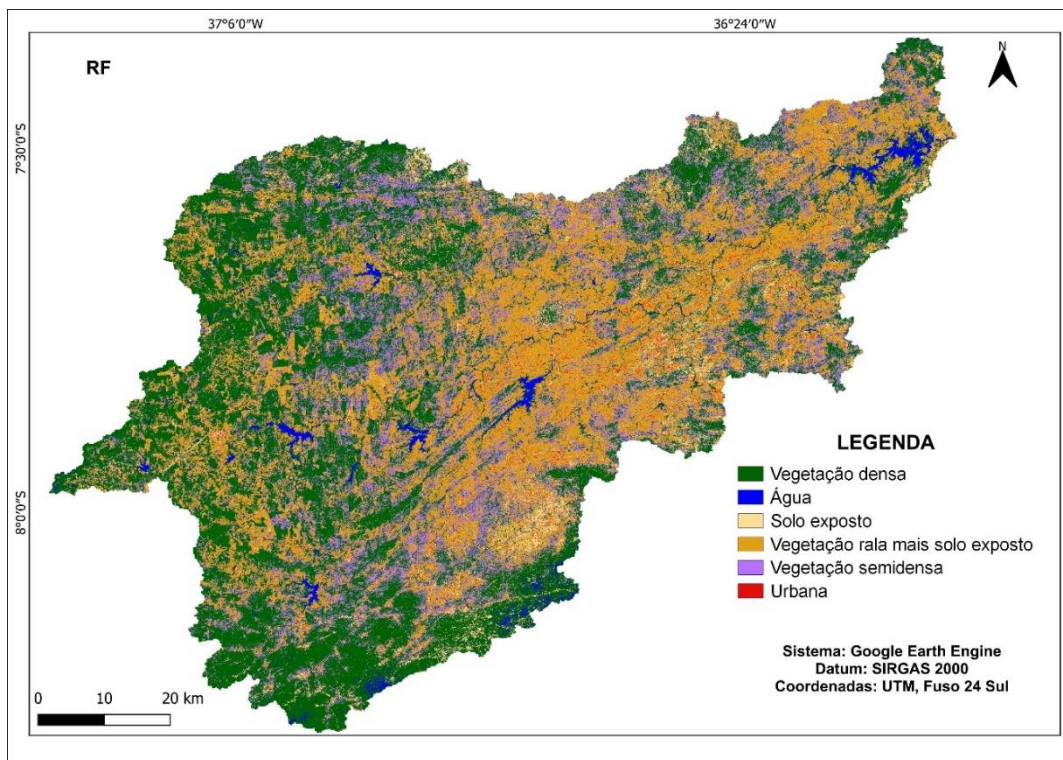
Classificador	CART		RF		MMD	
	(A.P)	(A.U)	(A.P)	(A.U)	(A.P)	(A.U)
	-----%-----					
VD	80,09	79,67	83,98	84,83	60,07	89,18
A	99,12	98,44	99,56	99,39	95,81	78,42
SE	74,38	73,82	85,19	77,14	51,99	72,67
VRMSE	92,92	93,13	96,78	93,64	77,11	88,68
VS	53,17	54,02	64,92	64,86	84,70	46,49
UR	49,36	50,00	41,27	75,78	25,53	18,57

Legenda: VD = Vegetação densa; A = Água; SE = Solo Exposto; VRMSE = Vegetação rala mais solo exposto; VS = Vegetação semidensa; UR = Urbana; A.G = Acurácia Geral; I.K = Índice Kappa. Fonte: Adaptado de Sousa (2023).

Johansen et al. (2015), utilizaram imagens LANDSAT no GEE para mapear a degradação da vegetação em Queensland-AUS. O estudo comparou abordagens de classificação, destacando que os classificadores CART e RF apresentaram maior precisão na detecção de mudanças na vegetação lenhosa em comparação com mapas governamentais. A precisão variou de 78 a 92% para o mapeamento do usuário e de 55 a 77% para o mapeamento do produtor.

Com base nas informações apresentadas na Tabela 1, e pela Figura 3 do mapa de LULC gerado pelo algoritmo RF para o ano de 2021, é perceptível que a categoria de vegetação densa (nativa) abrange uma extensão de 278.424,42 ha, correspondendo a uma proporção de 40,72%.

Figura 3. Mapa de LULC relacionado ao algoritmo RF.



Fonte: Autores (2024).

Ao cotejar com o estudo empreendido por Francisco et al. (2021), onde identificaram um índice de 36,7% da extensão total da bacia hidrográfica do Alto Curso do rio Paraíba ocupada pela categoria de vegetação densa, durante o ano de 2003. A cobertura vegetal natural é um importante indicador das condições ambientais de uma bacia hidrográfica, pois protege o solo, favorece a recarga de água, reduz o transporte de sedimentos e o assoreamento dos corpos d'água e serve como habitat de animais silvestres (NEVES et al., 2014; KARAMAGE et al., 2016; VANACKER et al., 2019; DOU et al., 2020). Além disso, contribuem para o equilíbrio dos agroecossistemas, pois abrigam inimigos naturais e polinizadores (ALVES et al., 2021).

As regiões com menor cobertura vegetal no solo, representadas pela classe de vegetação rala mais solo exposto, abrangem uma extensão de 217.780,50 ha, o que equivale a 31,85% da área total da bacia, estendendo-se ao longo da drenagem. Constata-se um aumento nessa categoria em comparação com o estudo de Francisco et al. (2021), que identificaram um percentual de 14,83%, destacando que essas áreas são mais intensamente exploradas para fins agrícolas na região. A redução vegetação remove a proteção do solo contra processos erosivos, além disso, em áreas semiáridas os processos erosivos estão relacionados aos processos de desertificação levando a



ciclos viciosos cumulativos de menor produção, empobrecimento comunitário e ocupação de terras agrícolas marginais e menos apropriadas (BARBOSA NETO et al., 2021).

Pastagens herbáceas ou culturas de ciclo curto substituem a vegetação arbustiva e arbórea predominante da Caatinga na região semiárida brasileira. Para piorar ainda mais a situação, um sistema de cultivo contínuo sem nutrientes se reposiciona após a colheita e, na maioria das vezes, esse sistema é combinado com o pastoreio excessivo de gado nas ervas e arbustos, o que leva à perda de fertilidade do solo e dificulta o crescimento da vegetação (SAMPAIO et al., 2003; PEREZ-MARIN et al., 2006; MENEZES et al., 2012; ALTHOFF et al., 2018; BARBOSA NETO et al., 2021). Além disso, parte significativa da região semiárida brasileira tem seus recursos naturais degradados pelos atuais sistemas de produção agrícola e pecuária (BARBOSA NETO et al., 2021).


As extensões designadas para a classe vegetação semidensa, abrangem uma superfície de 129.745,96 hectares, equivalente a 18,98% da área em análise para o ano de 2021. Ao efetuar uma comparação com o estudo de Francisco et al. (2021), é perceptível um aumento nessa extensão. Esses pesquisadores apontaram que essa categoria representava 8,54% da área da bacia hidrográfica do Alto Curso do rio Paraíba no ano de 2003. As conversões da caatinga em pastagens e vice-versa representam uma séria ameaça aos recursos naturais da bacia, uma vez que as mudanças descontroladas no LULC, juntamente com as mudanças climáticas, podem causar um cenário de degradação irreversível na região da Caatinga (BRITO MORAIS et al., 2017; CASTANHO et al., 2020).

É possível observar que, a classe solo exposto engloba uma extensão de 33.114,83 hectares, representando 4,84% da área total da bacia. No estudo de Francisco et al. (2021), realizado para o ano de 2003, foi identificado que a classe de solo exposto abrangia 21,72% da área da bacia. Os autores enfatizam que, as imagens correspondem ao período seco de 2003, o que parcialmente explica o maior grau de degradação ou dormência da cobertura vegetal, algo típico da caatinga hiperxerófila em condições secas. Isso contribui para o valor elevado associado a essa categoria.

Em relação à classe urbana, verifica-se que engloba uma superfície de 11.810,88 hectares, equivalente a 1,73% da área total da bacia. O crescimento das áreas urbanas em nosso estudo segue os padrões mundiais e está associado ao desenvolvimento econômico do país e da região (VERGOLINO e DANTAS, 2005).

Neste estudo, é evidente que a classe água, abrange uma extensão de 12.846,07 hectares, correspondendo a 1,88% da área total da bacia. Isso é notório na Figura 3, que destaca principalmente os principais açudes da região. Cardoso (2016) observou uma porcentagem de 1,16% para a classe água em 2005, considerando a mesma área de estudo. Em uma pesquisa conduzida por Francisco et al. (2021), para o ano de 2010, foi determinado um percentual de 0,97% para a classe de água. Nas regiões semiáridas do Brasil, a irregularidade e o baixo volume de chuvas associados à alta incidência de radiação e às altas temperaturas limitam a disponibilidade de água nos reservatórios (SILVA et al., 2010). Essas condições podem se agravar devido às mudanças climáticas, que devem aumentar ainda mais a temperatura e reduzir o volume de chuvas, o que dificultará o gerenciamento do abastecimento de água (PINTO e CENTENO, 2016).

A avaliação aponta notáveis alterações na ocupação e paisagem da bacia ao longo das décadas, em consonância com estudos em áreas áridas e semiáridas, como a bacia do rio Taperoá e



Sucuru no nordeste do Brasil (SOUSA et al., 2022; SOUSA et al., 2023), mapeamento da cobertura do solo na região semiárida do norte da Nigéria (ABUBAKAR et al., 2023) e detecção de transformações no LULC na bacia do baixo Bhavani no sul da Índia (KARISHMA et al., 2022). Os serviços de computação em nuvem, como o GEE, podem fornecer informações sobre o LULC de longo prazo em uma ampla área (MIDEKISA et al., 2017).

Conclusões

Entre os três classificadores utilizados nesse estudo, os resultados obtidos pelo algoritmo RF, foram satisfatórios e produziram boa precisão, apresentando os melhores valores de índice Kappa, Acuracia Geral, Acurácia do Produtor e Usuário.

A aplicação do GEE demonstrou ser uma plataforma muito eficaz para a realização da classificação do LULC, trazendo consigo soluções eficaz com agilidade e exatidão.

Agradecimentos

Ao CNPq - Brasil, pela concessão da bolsa aos autores. Ao Ministério Público de Mato Grosso do Sul pela concessão de bolsa de pós-graduação no CEIPPAM/UCDB.

Referências

ABUBAKAR, G. A.; WANG, K.; KOKO, A. F.; HUSSEINI, M. I.; SHUKA, K. A. M.; DENG, J.; GAN, M. Mapping Maize Cropland and Land Cover in Semi-Arid Region in Northern Nigeria Using Machine Learning and Google Earth Engine. *Remote Sensing*, v. 15, n. 11, e2835, 2023.

ADAM, E.; MUTANGA, O.; ODINDI, J.; ABDEL-RAHMAN, E. M. Land-use/cover classification in a heterogeneous coastal landscape using RapidEye imagery: evaluating the performance of random forest and support vector machines classifiers. *International Journal of Remote Sensing*, v. 35, n. 10, p. 3440-3458, 2014.

AGUILAR, R.; ZURITA-MILLA, R.; IZQUIERDO-VERDIGUIER, E.; BY, R. A. A cloud-based multi-temporal ensemble classifier to map smallholder farming systems. *Remote Sensing*, v. 10, n. 5, e729, 2018.

ALAM, A.; BHAT, M. S.; MAHEEN, M. Using Landsat satellite data for assessing the land use and land cover change in Kashmir valley. *GeoJournal*, v. 85, n. 6, p. 1529-1543, 2020.

ALTHOFF, T. D.; MENEZES, R. S. C.; SIQUEIRA PINTO, A.; PAREYN, F. G. C.; CARVALHO, A. L.; MARTINS, J. C. R.; CARVALHO, E. X.; SILVA, A. S. A.; DUTRA, E. D.; SAMPAIO, E. V. D. S. B. Adaptation of the century model to simulate C and N dynamics of Caatinga dry forest before and after deforestation. *Agriculture, Ecosystems & Environment*, v. 254, n. 1, p. 26-34, 2018.

ALVES, W. S.; MARTINS, A. P.; PÔSSA, É. M.; MOURA, D. M. B.; MORAIS, W. A.; FERREIRA, R. S.; SANTOS, L. N. S. Geotechnologies applied in the analysis of land use and land cover (LULC) transition in a hydrographic basin in the Brazilian Cerrado. *Remote Sensing Applications: Society and Environment*, v. 22, n. 1, e100495, 2021.

ARPITHA, M.; AHMED, S. A.; HARISHNAIKA, N. Land use and land cover classification using machine learning algorithms in Google Earth Engine. *Earth Science Informatics*, v. 1, n. 1, p. 1-17, 2023.

BARBOSA NETO, M. V.; ARAÚJO, M. D. S. B.; ARAÚJO FILHO, J. C.; SAMPAIO, E. V. D. S. B.; ALMEIDA, B. G. Rill and sheet soil erosion estimation in an area undergoing desertification in the Brazilian semi-arid region. *Modeling Earth Systems and Environment*, v. 7, n. 1, p. 1183-1191, 2021.



SOUSA, J. H. S. de; RIBEIRO, G. do N.; FRANCISCO, P. R. M.; CARVALHO, W. dos S. Aplicação de geotecnologias no uso e cobertura da terra na bacia hidrográfica do Alto Curso do rio Paraíba. *Revista Semiárido De Visu*, v. 12, n. 2, p. 644-657, maio 2024. ISSN 2237-1966.

BECKER, W. R.; LÓ, T. B.; JOHANN, J. A.; MERCANTE, E. Statistical features for land use and land cover classification in Google Earth Engine. *Remote Sensing Applications: Society and Environment*, v. 21, n. 1, e100459, 2021.

BREIMAN, L. Random forests. *Machine Learning*, v. 45, n. 1, p. 5-32, 2001.

BRITO, H. C.; BRITO, Y. M. A.; RUFINO, I. A. A. O índice de segurança hídrica do Brasil e o semiárido brasileiro: desafios e riscos futuros. *Revista Brasileira de Cartografia*, v. 74, n. 1, p. 1-15, 2022.

BRITO MORAIS, Y. C.; BEZERRA DE ARAÚJO, M. D. S.; MOURA, M. S. B.; GALVÍNCIO, J. D.; QUEIROGA MIRANDA, R. Análise do Sequestro de Carbono em áreas de Caatinga do Semiárido Pernambucano. *Revista Brasileira de Meteorologia*, v. 32, n. 1, p. 585-599, 2017.

CARDOSO, E. C. M. **Análise espaço-temporal do risco à desertificação no Auto Curso do rio Paraíba/PB a partir das modificações na caatinga.** Trabalho de Conclusão de Curso (Graduação em Geografia) - Departamento de Geociências, Universidade Federal da Paraíba - UFPB, João Pessoa. 26p. 2016.

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.

CUI, J.; ZHU, M.; LIANG, Y.; QIN, G.; LI, J.; LIU, Y. Land use/land cover change and their driving factors in the Yellow River Basin of Shandong Province based on Google Earth Engine from 2000 to 2020. *International Journal of Geo-Information*, v. 11, n. 3, e163, 2022.

DONG, J.; XIAO, X.; MENARGUEZ, M. A.; ZHANG, G.; QIN, Y.; THAU, D.; BIRADAR, C.; MOORE III, B. Mapping paddy rice planting area in northeastern Asia with Landsat 8 images, phenology-based algorithm and Google Earth Engine. *Remote Sensing of Environment*, v. 185, n. 1, p. 142-154, 2016.

DOU, Y.; YANG, Y.; AN, S.; ZHU, Z. Effects of different vegetation restoration measures on soil aggregate stability and erodibility on the Loess Plateau, China. *Catena*, v. 185, n. 1, e104294, 2020.


FOODY, G. M.; MATHUR, A. A relative evaluation of multiclass image classification by support vector machines. *Transactions on Geoscience and Remote Sensing*, v. 42, n. 6, p. 1335-1343, 2004.

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: FRANCISCO, P. R. M.; FURTADO, D. A.; FERREIRA, A. C. (org.). *Engenharia, Agronomia e Geociência 2014-2021*. Campina Grande: EPTec, pp. 37-53. 2021.

FRIEDL, M. A.; MCIVER, D. K.; HODGES, J. C.; ZHANG, X. Y.; MUCHONEY, D.; STRAHLER, A. H.; WOODCOCK, C. E.; GOPAL, S.; SCHNEIDER, A.; COOPER, A.; BACCINI, A.; GAO, F.; SCHAAF, C. Global land cover mapping from MODIS: algorithms and early results. *Remote Sensing of Environment*, v. 83, n. 2, p. 287-302, 2002.

FURTADO, A. V. B. D.; SOUZA, P. O. J. Mapeamento geomorfológico para a bacia do Alto Curso do Rio Paraíba de acordo com as normas do Manual Geomorfológico do IBGE. *Revista de Geociências do Nordeste*, v. 2, n. 1, p. 83-91, 2016.

GHIMIRE, B.; ROGAN, J.; GALIANO, V. R.; PANDAY, P.; NEETI, N. An evaluation of bagging, boosting, and random forests for land-cover classification in Cape Cod, Massachusetts, USA. *GIScience & Remote Sensing*, v. 49, n. 5, p. 623-643, 2012.



GISLASON, P. O.; BENEDIKTSSON, J. A.; SVEINSSON, J. R. Random forests for land cover classification. *Pattern Recognition Letters*, v. 27, n. 4, p. 294-300, 2006.

GOLDBLATT, R.; YOU, W.; HANSON, G.; KHANDELWAL, A. K. Detecting the boundaries of urban areas in india: A dataset for pixel-based image classification in google earth engine. *Remote Sensing*, v. 8, n. 8, e634, 2016.

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, n. 1, p. 18-27, 2017.

HANSEN, M. C.; POTAPOV, P. V.; MOORE, R.; HANCHER, M.; TURUBANOVA, S. A.; TYUKAVINA, A.; THAU, D.; STEHMAN, S. V.; GOETZ, S. J.; LOVELAND, T. R.; KOMMAREDDY, A.; EGOROV, A.; CJINI, L.; JUSTICE, C. O.; TOWNSHEND, J. High-resolution global maps of 21st-century forest cover change. *Science*, v. 342, n. 6160, p. 850-853, 2013.

JOHANSEN, K.; PHINN, S.; TAYLOR, M. Mapping woody vegetation clearing in Queensland, Australia from Landsat imagery using the Google Earth Engine. *Remote Sensing Applications: Society and Environment*, v. 1, n. 1, p. 36-49, 2015.

KARAMAGE, F.; SHAO, H.; CHEN, X.; NDAYISABA, F.; NAHAYO, L.; KAYIRANGA, A.; OMIFOLAJI, J. K.; LIU, T.; ZHANG, C. Deforestation effects on soil erosion in the Lake Kivu Basin, DR Congo-Rwanda. *Forests*, v. 7, n. 11, e281, 2016.

KARISHMA, C. G.; KANNAN, B.; NAGARAJAN, K.; PANNEERSELVAM, S.; PAZHANIVELAN, S. Land use land cover change detection in the lower Bhavani basin, Tamil Nadu, using geospatial techniques. *Journal of Applied and Natural Science*, v. 14, n. 1, p. 58-64, 2022.

KHATAMI, R.; MOUNTRAKIS, G.; STEHMAN, S. V. A meta-analysis of remote sensing research on supervised pixel-based land-cover image classification processes: General guidelines for practitioners and future research. *Remote Sensing of Environment*, v. 177, n. 1, p. 89-100, 2016.

LAWRENCE, R. L.; WRIGHT, A. Rule-based classification systems using classification and regression tree (CART) analysis. *Photogrammetric Engineering and Remote Sensing*, v. 67, n. 10, p. 1137-1142, 2001.

LU, D.; WENG, Q. A survey of image classification methods and techniques for improving classification performance. *International Journal of Remote Sensing*, v. 28, n. 5, p. 823-870, 2007.

MATHER, P.; TSO, B. *Classification methods for remotely sensed data*. Boca Raton: CRC Press, 2009. 349p.

MAXWELL, A. E.; WARNER, T. A.; FANG, F. Implementation of machine-learning classification in remote sensing: An applied review. *International Journal of Remote Sensing*, v. 39, n. 9, p. 2784-2817, 2018.

MENEZES, R. S. C.; SAMPAIO, E. V. S. B.; GIONGO, V.; PÉREZ-MARIN, A. M. Biogeochemical cycling in terrestrial ecosystems of the Caatinga Biome. *Brazilian Journal of Biology*, v. 72, n. 3, p. 643-653, 2012.

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

MURTAZA, K. O.; ROMSHOO, S. A. Determining the suitability and accuracy of various statistical algorithms for satellite data classification. *International Journal of Geosciences and Geomatics*, v. 4, n. 4, p. 585-599, 2014.

NEVES, L. F. S.; NEVES, S. M. A. S.; CANALE, G. R. Análise da fragmentação de cerrado na bacia



SOUSA, J. H. S. de; RIBEIRO, G. do N.; FRANCISCO, P. R. M.; CARVALHO, W. dos S. Aplicação de geotecnologias no uso e cobertura da terra na bacia hidrográfica do Alto Curso do rio Paraíba. *Revista Semiárido De Visu*, V. 12, n. 2, p. 644-657, maio 2024. ISSN 2237-1966.

hidrográfica do rio Aguapei, Porto Esperidião (MT): um estudo de caso a partir das geotecnologias e métricas da paisagem. *Ateliê Geográfico*, v. 8, n. 2, p. 130-149, 2014.

PADARIAN, J.; MINASNY, B.; MCBRATNEY, A. B. Using Google's cloud-based platform for digital soil mapping. *Computers & Geosciences*, v. 83, n. 1, p. 80-88, 2015.

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, n. 1, p. 199-208, 2015.

PEREZ-MARIN, A. M.; MENEZES, R. S. C.; SILVA, E. D.; SAMPAIO, E. V. D. S. B. Efeito da *Gliricidia sepium* sobre nutrientes do solo, microclima e produtividade do milho em sistema agroflorestal no Agreste Paraibano. *Revista Brasileira de Ciência do Solo*, v. 30, n. 3, p. 555-564, 2006.

PINTO, G. D. R. M.; CENTENO, J. A. S. Monitoramento do espelho d'água da represa do Vossorooca entre 2010-2015 usando dados Landsat. *Revista Brasileira de Geomática*, v.4, n.3, p.163-168, 2016.

SAMPAIO, E. V. S. B.; SAMPAIO, Y. D. S. B.; VITAL, T.; ARAÚJO, M. S. B.; SAMPAIO, G. R. **Desertificação no Brasil: conceitos, núcleos e tecnologias de recuperação e convivência**. Recife: Editora Universitária/UFPE, 2003. 202p.

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**. Dissertação (Mestrado em Tecnologias Energéticas e Nucleares) - Departamento De Energia Nuclear, Universidade Federal de Pernambuco - UFPE, Recife. 61p. 2021.

SARAIVA-MAIA, J. J. O.; SANTOS, D. L. N.; SOUZA, A. L. E.; SILVA, M. D.; ALMEIDA, N. V. Vulnerabilidade à erosão do solo na Bacia Hidrográfica do Baixo São Francisco: uma visão integrada entre geomorfologia e cobertura e uso da terra. *Revista Contexto Geográfico*, v. 9, n. 18, p. 468-484, 2024.

SCEPAN, J. Thematic validation of high-resolution global land-cover data sets. *Photogrammetric Engineering and Remote Sensing*, v. 65, n. 9, p. 1051-1060, 1999.

SHELESTOV, A.; LAVRENIUK, M.; KUSSUL, N.; NOVIKOV, A.; SKAKUN, S. Exploring Google Earth Engine platform for big data processing: Classification of multi-temporal satellite imagery for crop mapping. *Frontiers in Earth Science*, v. 5, n. 1, e17, 2017.

SILVA, P. C. G.; MOURA, M. S. B.; KIILL, L.H. P.; BRITO, L. T. L.; PEREIRA, L. A.; SÁ, I. B.; CORREIA, R. C.; TEIXEIRA, A. H. C.; CUNHA, T. J. F.; GUIMARÃES-FILHO, C. G. Caracterização do Semiárido brasileiro: fatores naturais e humanos. In: SA, I. B.; SILVA, P. C. G. (org). **Semiárido brasileiro: pesquisa, desenvolvimento e inovação**. Petrolina: Embrapa Semiárido, pp. 18-48. 2010.

SOUSA, M. L. M.; NASCIMENTO, F. R. Estudos geoambientais de bacias hidrográficas em áreas suscetíveis à desertificação no Nordeste do Brasil. *Cuadernos de Geografía: Revista Colombiana de Geografía*, v. 24, n. 1, p. 13-42, 2015.

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

SOUSA, J. H. S. **Aplicação do algoritmo Random Forest para classificação do uso e cobertura da terra na Bacia Hidrográfica do Rio Scuru utilizando o Google Earth Engine**. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Biosistemas) - Centro de Desenvolvimento Sustentável do Semiárido, Universidade Federal de Campina Grande, Sumé. 43p. 2023.

SOUSA, J. H. S.; RIBEIRO, G. N.; FRANCISCO, P. R. M.; NASCIMENTO, A. A.; ALVES, J. I. P.; CAVALCANTI, M. Classificação e mapeamento do uso e cobertura das terras da bacia hidrográfica do



SOUSA, J. H. S. de; RIBEIRO, G. do N.; FRANCISCO, P. R. M.; CARVALHO, W. dos S. Aplicação de geotecnologias no uso e cobertura da terra na bacia hidrográfica do Alto Curso do rio Paraíba. *Revista Semiárido De Visu*, V. 12, n. 2, p. 644-657, maio 2024. ISSN 2237-1966.

rio Taperoá-PB utilizando o Google Earth Engine. *Revista Geama*, v. 9, n. 2, p. 44-52, 2023.

STEHMAN, S. V.; FOODY, G. M. Key issues in rigorous accuracy assessment of land cover products. *Remote Sensing of Environment*, v. 231, n. 1, e111199, 2019.

TALUKDAR, S.; SINGHA, P.; MAHATO, S.; PAL, S.; LIOU, Y. A; RAHMAN, A. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. *Remote Sensing*, v. 12, n. 7, e1135, 2020.

VANACKER, V.; AMEIJERAS-MARIÑO, Y.; SCHOONEJANS, J.; CORNÉLIS, J. T.; MINELLA, J. P. G.; LAMOULIN, F.; VERMEIRE, M. L.; CAMPFORTS, B.; ROBINET, J.; BROEK, M. V.; DELMELLE, P.; OPFERGLT, S. Land use impacts on soil erosion and rejuvenation in Southern Brazil. *CATENA*, v. 178, n. 1, p. 256-266, 2019.

VERGOLINO, J. R.; DANTAS, M. Os determinantes do processo de urbanização da região Nordeste do Brasil: 1970-1996. *Revista de Economia*, v. 31, n. 2, p. 7-33, 2005.

YU, L.; LIANG, L.; WANG, J.; ZHAO, Y.; CHENG, Q.; HU, L.; LIU, S.; YU, L.; WANG, X.; ZHU, P.; LI, X.; XU, Y.; LI, C.; FU, W.; LI, X.; LI, W.; LIU, C.; CONG, N.; ZHANG, H.; SUN, F.; BI, X.; XIN, Q.; LI, D.; YAN, D.; ZHU, Z.; GOODCHILD, M. F.; GONG, P. Meta-discoveries from a synthesis of satellite-based land-cover mapping research. *International Journal of Remote Sensing*, v. 35, n. 13, p. 4573-4588, 2014.

ZHANG, D. D.; ZHANG, L. Land Cover Change in the Central Region of the Lower Yangtze River Based on Landsat Imagery and the Google Earth Engine: A Case Study in Nanjing, China. *Sensors*, v. 20, n. 7, e2091, 2020.

ZURQANI, H. A.; POST, C. J.; MIKHAILOVA, E. A.; SCHLAUTMAN, M. A.; SHARP, J. L. Geospatial analysis of land use change in the Savannah River Basin using Google Earth Engine. *International Journal of Applied Earth Observation and Geoinformation*, v. 69, n. 1, p. 175-185, 2018.