



## Classificação e mapeamento do uso e cobertura das terras da bacia hidrográfica do rio Taperoá-PB utilizando o Google Earth Engine

### *Classification and mapping of land use and land cover of the Taperoá-PB river basin using Google Earth Engine*

José Hugo Simplicio de Sousa<sup>1</sup>, George do Nascimento Ribeiro<sup>1</sup>, Paulo Roberto Megna Francisco<sup>1</sup>, Abdalan Andrade do Nascimento<sup>2</sup>, José Ilton Pereira Alves<sup>1</sup>, Miriany Cavalcanti<sup>1</sup>

<sup>1</sup> Universidade Federal de Campina Grande, Paraíba, Brasil

<sup>2</sup> União de Ensino Superior de Campina Grande, Paraíba, Brasil

Contato: [hugosimplicio123@gmail.com](mailto:hugosimplicio123@gmail.com)

#### Palavras-Chave

semiárido  
sensoriamento remoto  
sentinel-2  
avaliação de precisão

#### Keywords

semi-arid  
remote sensing  
sentinel-2  
accuracy assessment

#### RESUMO

As geotecnologias vêm se mostrando promissoras para aplicação da prática na análise de dados ambientais para recursos naturais terrestres. Ao longo do tempo, as características naturais da Bacia Hidrográfica do rio Taperoá localizada em região semiárida no Estado da Paraíba, foi se modificando devido às atividades antrópicas. O objetivo deste trabalho foi classificar o uso e cobertura da terra atual, utilizando imagens Sentinel-2. Foi aplicado quatro algoritmos de classificação supervisionados disponíveis no Google Earth Engine (GEE). Os resultados demonstraram que o classificador baseado em árvore de decisão Random Forest (RF), se destacou em relação aos outros classificadores tanto na precisão de classificação quanto na inspeção visual para o uso e cobertura da terra. A plataforma Google Earth Engine demonstrou desempenho satisfatório em termos de processamento computacional, possibilitando o estudo de dados ambientais em larga escala, permitindo a identificação de mudanças no uso e cobertura do solo.

#### ABSTRACT

Geotechnologies have been showing promise for the application of practice in the analysis of environmental data for terrestrial natural resources. Over time, the natural characteristics of the Taperoá River Basin located in a semi-arid region in the State of Paraíba, has been changing due to anthropogenic activities. The objective of this work was to classify the current land use and land cover using Sentinel-2 images. Four supervised classification algorithms available in Google Earth Engine (GEE) were applied. The results showed that the Random Forest (RF) decision tree-based classifier stood out over the other classifiers in both classification accuracy and visual inspection for land use and land cover. The Google Earth Engine platform demonstrated satisfactory performance in terms of computational processing, enabling the study of large-scale environmental data, allowing the identification of changes in land use and land cover.

#### Informações do artigo

Recebido: 08 de maio, 2023

Aceito: 16 de agosto, 2023

Publicado: 23 de agosto, 2023

## Introdução

Entender a integração entre sistemas humanos e ambientais complexos, analisando suas causas, consequências e efeitos é essencial para organizar o uso da terra e obter informações que melhorem a gestão de bacias hidrográficas e ambientes (TANG et al., 2009; GU et al., 2021).

Por apresentar formas de ocupação da paisagem, as informações sobre uso e cobertura da terra são essenciais para diversas aplicações geoespaciais, como planejamento e gestão ambiental. Também serve como base para entender as relações entre a cobertura da terra e os serviços ecossistêmicos (LIU et al., 2017; ZHANG et al., 2019). Uma melhor compreensão das consequências das mudanças na cobertura da terra nos processos hidrológicos pode ser útil para a tomada de decisões e para a gestão de bacias hidrográficas (ALVARENGA et al., 2016).

As mudanças no uso e na cobertura da terra podem afetar a biodiversidade, os ciclos biogeoquímicos de carbono e nitrogênio, o balanço energético, o escoamento de água, entre outros (DEVARAJU et al., 2018; DUVEILLER et al., 2018; WINCKLER et al., 2019; CHEMURA et al., 2020). Isso também pode levar a uma redução no fornecimento de serviços ecossistêmicos (RIMAL et al., 2019). 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 podem apoiar nossa compreensão dos sistemas humanos e ambientais. Além disso, são dados importantes para modelagem ambiental e gestão de recursos hídricos (STEINHAUSEN et al., 2018; WAGNER et al., 2019).

Existem várias técnicas usadas na análise de mudança de uso e cobertura da terra. Os dados de sensoriamento remoto têm uma vantagem no monitoramento da detecção de mudanças na cobertura da terra devido à grande cobertura espacial, alta resolução temporal e ampla disponibilidade (ZURQANI et al., 2018).

A utilização de plataformas baseadas em nuvens que disponibilizam séries temporais de longos períodos e de softwares livres, permitem a realização de pesquisas com aplicações metodológicas acessíveis e de baixo custo. Materiais que norteiam sobre o uso e cobertura da terra são importantes ferramentas para orientar as tomadas de decisões em relação aos recursos hídricos e outras temáticas ambientais (FREITAS et al., 2021).

A plataforma de computação em nuvem Google Earth Engine (GEE) possibilita a análise de dados ambientais em larga escala e com amplos recursos computacionais, pois utiliza os servidores do Google para processamento e armazenamento, aliado a um ambiente para implementação de algoritmos em linguagens Java Script. Esse modelo de computação distribuída *just-in-time* permite a exploração em tempo real dos resultados e a análise de dados experimentais (GORELICK et al., 2017). Até o momento, vários estudos utilizaram GEE para classificação de uso e cobertura da terra, como Li et al. (2020), em que exploraram as imagens Sentinel-2 e Landsat-8 para gerar um mapa de 10 m de todo o Continente Africano por um classificador Random Forest (RF). Ghorbanian et al. (2020), também aproveitou os dados do Sentinel para classificar uma área de grande escala usando RF em uma resolução espacial de 10 m e 13 classes de uso e cobertura da terra.

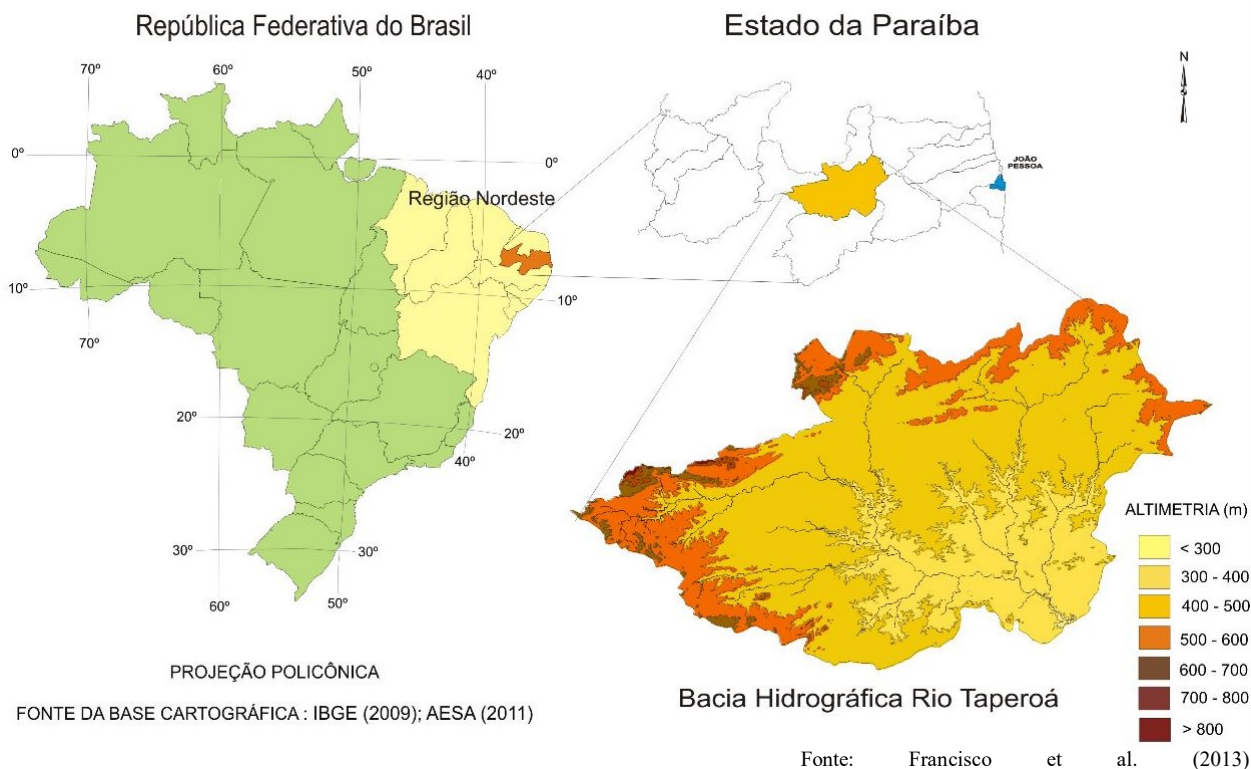
Portanto, o objetivo deste trabalho é realizar o mapeamento do uso e cobertura da terra na Bacia Hidrográfica do rio Taperoá, cariri paraibano, para o ano de 2021, utilizando a plataforma do Google Earth Engine (GEE).

## Material e Métodos

A Bacia Hidrográfica do Rio Taperoá situa-se em uma região que está entre as mais secas do Brasil, regionalmente conhecida como Cariri Paraibano. Encontra-se inseridos total ou parcialmente em 19 municípios, drena aproximadamente uma área de 5.667,49 km<sup>2</sup>, nasce na Serra do Teixeira e desemboca no Rio Paraíba, no açude Boqueirão. O rio principal possui uma extensão de 158 km. Configura-se, em uma região semiárida, com chuvas distribuídas de forma irregular durante o ano (SANTOS et al., 2019).

A área da bacia apresenta relevo suave ondulado, e altitudes variando predominantemente entre 400 a 600 m (Figura 1). A drenagem voltada para o sudeste facilita a penetração uniforme das massas atlânticas propiciando um gradiente uniforme de temperatura e precipitação, à medida que ocorre a elevação do terreno (FRANCISCO et al., 2012a). A Bacia Hidrográfica do rio Taperoá apresenta clima do tipo tropical semiárido (clima quente e seco – BSh), segundo a classificação climática de Köppen. Essa região se caracteriza por chuvas de verão, com temperaturas elevadas superiores a 27°C. A amplitude térmica da bacia varia de 3 a 5°C, e a umidade relativa do ar é de aproximadamente 78% (DANTAS et al., 2015).

Figura 1. Localização da área de estudo



A vegetação é do tipo caatinga hiperxerófila, em sua maior parte de porte baixo, que divide espaço com lavouras de palma forrageira, algodão e agave (estas duas últimas de caráter mais voltado ao comércio), assim como lavouras temporárias de milho e feijão, que representam uma pequena área da bacia (SOUZA et al., 2004; FRANCISCO et al., 2013).

Os solos predominantes na área de estudo são o Luvisolo Crômico Vértico, com fase pedregosa e relevo suave ondulado, Vertissolo, com relevo suave ondulado e ondulado nas partes mais baixas, Neossolo Regolítico e o Planossolo Nátrico, com relevo plano e suave ondulado, no centro-norte e nas áreas mais acidentadas, e o Neossolo Litólico Eutrófico, com fase pedregosa substrato gnaisse e granito (FRANCISCO et al., 2012b).

Seabra et al. (2014), afirmam que a pecuária é a principal atividade econômica da bacia, e que sua expansão ao longo dos últimos anos vem contribuindo para a progressiva redução e transformação da cobertura vegetal de Caatinga.

Todos os procedimentos metodológicos foram realizados através de script na linguagem JavaScript, inseridos no API do GEE. O mapeamento do uso e cobertura da terra começou com a delimitação da área de estudo no GEE, usando dados vetoriais externos e ferramentas de interface do GEE para selecionar a área sobre os planos de informação de base. Para esta pesquisa, a área classificada foi sobreposta às cenas das órbitas 24MYU e 24MYT do sistema SENTINEL-2. Foram aplicados filtros nos metadados das imagens para eliminar áreas com cobertura excessiva de nuvens, mantendo um limiar de cobertura de nuvens inferior a 1% em cada

imagem. Para criar a imagem final, foi aplicado um filtro de mediana no conjunto de imagens Sentinel-2, abrangendo o período de 01/01 a 31/12/2021, usando o comando "*ee.ImageCollection().median()*". Dessa forma, obteve-se uma imagem única e representativa do ano de 2021 da Bacia Hidrográfica do rio Taperoá.

As amostras para o processo de classificação foram selecionadas a partir de composições RGB das imagens do sensor MSI (Multispectral Instrument). Com base nessas composições, foram escolhidas 5 classes para a classificação do uso e cobertura da terra, considerando o tipo de ocupação predominante na bacia em estudo: vegetação densa (nativa), semidensa (silvicultura/pecuária), rala mais solo exposto (pecuária extensiva e/ou cultivos agrícolas), solo exposto e corpos hídricos (água).

Na imagem utilizada na classificação foi aplicado um filtro espacial de convolução 3x3, máscara kernel. Existem diferentes tipos de máscaras usadas para filtragem espacial, cada uma delas proporcionando um efeito de filtragem específico na imagem. Essas geralmente têm tamanhos de linhas e colunas variando de 3x3 a 7x7. Segundo Aedla et al. (2016), a filtragem por convolução é relativamente fácil de entender e é usada para aprimorar regiões de baixa e alta frequência, além de bordas nas imagens.

Em se tratando do bioma Caatinga, há especialmente duas dificuldades no mapeamento da distribuição espacial da cobertura da terra: a diversificação 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 (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).

Foram definidos os classificadores e os parâmetros para a validação do processo de classificação. Na interface do GEE, foram inseridos os algoritmos de classificação supervisionada, o Random Forest (RF), Minimum Distance - Euclidean (MMD), Library for Support Vector Machines (LibSVM) e Naive Bayes (BAYES).

As técnicas "*ee.Classifier.smileRandomForest*", "*ee.Classifier.minimumDistance*", "*ee.Classifier.libsvm*" e "*ee.Classifier.smileNaiveBayes*" foram respectivamente utilizadas para representar cada algoritmo, todos disponíveis no GEE.

Após estabelecer as 5 classes de uso e cobertura da terra como dados de entrada no modelo, o próximo passo é o processo de classificação, conduzido por uma função na interface do GEE que considera as variáveis

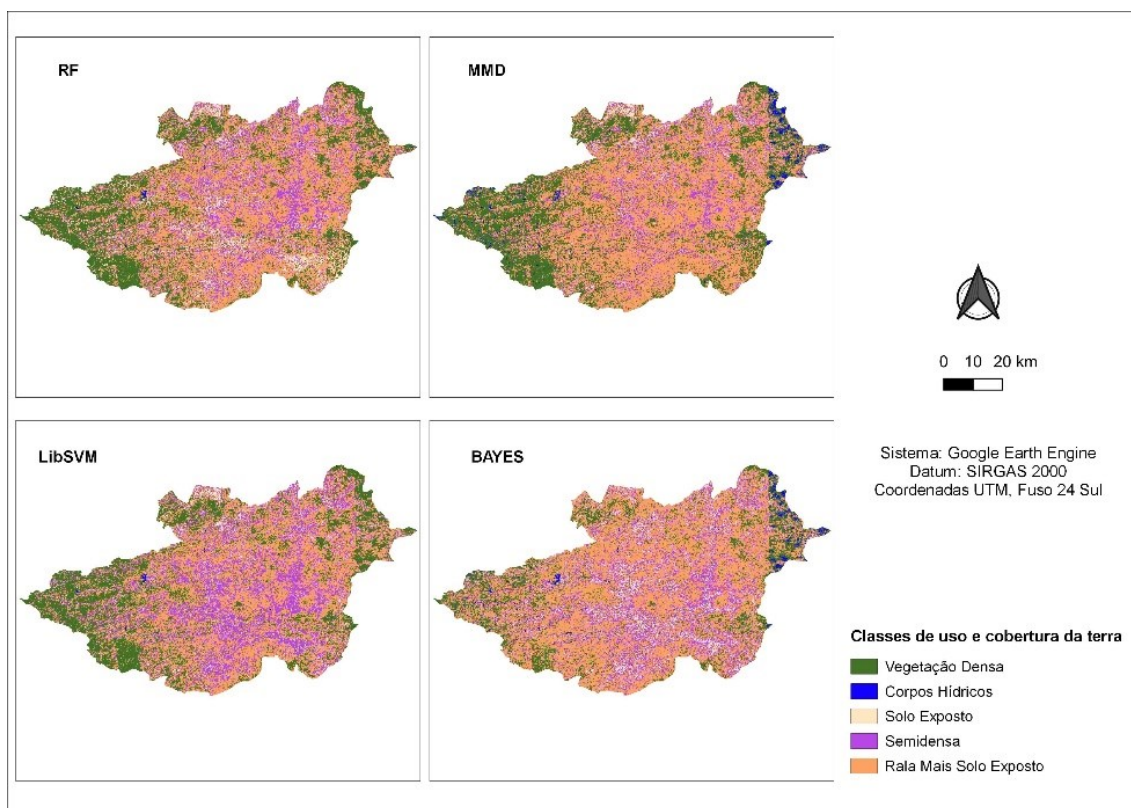
previamente definidas. Com base nos resultados da classificação, a qualidade das classificações foi avaliada estatisticamente utilizando o Índice de Kappa, Acurácia Geral, Acurácia do Produtor e Acurácia do Usuário, obtidos através da Matriz de Confusão, todos gerados pelo GEE. As imagens resultantes foram exportadas para o software QGIS® 3.0 para a elaboração dos mapas.

Segundo Silva et al. (2020), o índice kappa define uma medida de acurácia de acordo com a proporção em que uma área é corretamente classificada com base em uma referência, assumindo valores na faixa de 0 (uma classificação muito fraca) a 1 (uma classificação excelente). A Acurácia Geral representa a probabilidade de uma amostra ser corretamente classificada (ESTRABIS et al., 2019). A Acurácia do Produtor está associada aos erros de exclusão, ou seja, pixels que deixaram de ser mapeados. A Acurácia do Usuário está associada ao erro de omissão, ou seja, pixels classificados incorretamente (CAVALCANTE; LIMA, 2019).

## Resultados e Discussão

Pelos resultados obtidos observa-se um total de 1.083 pixels de amostras coletadas dispersas pela imagem de satélite. Em relação aos 5 grupos de demonstração/amostragem os pixels estão dispersos na classe densa em 303 pontos, semidensa em 217, rala mais solo exposto em 238, solo exposto em 215, e água em 110 (Figura 2). Observa-se que, apenas o classificador RF proporcionou os melhores resultados.

Figura 2. Uso e cobertura da terra referente aos classificadores RF, MMD, LibSVM e BAYES



Fonte: Adaptado de Google Earth Engine (2021)

Ou seja, uma menor confusão espectral no reconhecimento da cobertura do solo (Tabela 1). Esse resultado é validado por meio dos índices de avaliação de classificação de Acurácia Geral e Índice Kappa calculados automaticamente pelo GEE para os quatro modos de classificação.

Tabela 1. Dados e índices das imagens produto

| Classificador/<br>Classe | RF         |        | MMD        |        | LibSVM     |        | BAYES      |        |
|--------------------------|------------|--------|------------|--------|------------|--------|------------|--------|
|                          | Área (ha)  | (%)    | Área (ha)  | (%)    | Área (ha)  | (%)    | Área (ha)  | (%)    |
| Vegetação Densa          | 152.228,07 | 26,86  | 161.329,72 | 28,47  | 147.501,69 | 26,03  | 111.699,40 | 19,71  |
| Semidensa                | 273.427,68 | 48,24  | 308.359,17 | 54,41  | 254.198,66 | 44,85  | 317.100,59 | 55,95  |
| Rala Mais Solo Exposto   | 95.837,53  | 16,91  | 71.788,43  | 12,67  | 130.462,58 | 23,02  | 86.544,27  | 15,27  |
| Solo Exposto             | 43.635,04  | 7,70   | 16.429,40  | 2,90   | 26.810,27  | 4,73   | 44.588,10  | 7,87   |
| Corpos Hídricos          | 1.620,68   | 0,29   | 8.842,28   | 1,56   | 7.775,80   | 1,37   | 6.816,64   | 1,20   |
| Total                    | 566.749,00 | 100,00 | 566.749,00 | 100,00 | 566.749,00 | 100,00 | 566.749,00 | 100,00 |
| A.G (%)                  | *          | 99,16  | *          | 69,71  | *          | 87,07  | *          | 60,29  |
| I.K (%)                  | *          | 98,93  | *          | 62,01  | *          | 83,46  | *          | 50,76  |

Legenda: (RF): Random Forest; (MMD): Minimum Distance – Euclidean; (LibSVM): Library for Support Vector Machines; (BAYES): Naive Bayes; (A.G): Acurácia Geral; (I.K): Índice Kappa.

A melhor performance apresenta-se pelo classificador RF, com os valores de Acurácia Geral de 99,16% e Índice Kappa com 98,93%. Precisões de classificação de uso e cobertura da terra de pelo menos 85% são consideradas desejáveis em aplicações de sensoriamento remoto e gerenciamento de terras (NYBERG et al., 2015; GHEBREZGABHER et al., 2016).

Entretanto, o classificador MMD proporciona resultados inferiores, sendo a precisão de classificação quanto à inspeção visual, com valores de Acurácia Geral de 69,71% e Índice Kappa de 62,01%, continuada pelo método LibSVM apresentando valores de Acurácia Geral de 87,07% e Índice Kappa de 83,46%, e o método BAYES que apontou resultados da Acurácia Geral e Índice Kappa com 60,29 e 50,76%, respectivamente, apresentando-se abaixo de 85%. Os três classificadores retratam erros de omissão, dentre todas as classes, ou seja, classes que foram irregularmente mapeadas pelo classificador (algoritmo).

Com isso, Stehman e Foody (2019) relatam que, o limiar de 85% referente à avaliação das características de uso e cobertura do solo não tem status universal, apesar de às vezes seja usado como tal entre diversas pesquisas, a sua aplicação não tem que ser difundida, logo, os autores propuseram que, o dimensionamento da precisão dos mapeamentos é um domínio complexo de medir e apresentar exatidão.

Por exemplo, Kolli et al. (2020), demonstraram a capacidade do GEE em analisar a taxa de mudança no uso da terra ao redor do Lago Kolleru, na Índia, utilizando o algoritmo RF e obtendo uma Acurácia Geral de 95,9% com um Índice Kappa de 0,94%. Lowe e Kulkarni (2015), usaram os classificadores RF, SVM, e ML para mapear o

uso e cobertura da terra e alcançaram uma Acurácia Geral de 87, 83 e 77%, respectivamente. Esses diferentes resultados indicam que, não há regras claras para a precisão aceitável para qualquer tipo de cobertura do solo, mas depende do usuário e da metodologia adotada. Em qualquer classificação de uso e cobertura da terra, os erros estão presentes na forma de estimativa e previsão (SALOVAARA et al., 2005).

Até agora, nenhuma regra clara foi definida na faixa de precisão aceitável, porque diferentes usuários têm preocupações diferentes sobre a precisão da classificação (OLOFSSON et al., 2014). Além disso, vários fatores influenciam a precisão da classificação, como qualidade da imagem, classificador, número de classes e número de tamanho da amostra (NGUYEN et al., 2020). Nguyen et al. (2020), usaram dados do Sentinel-2 no estudo da classificação do uso e cobertura do solo na província de Dak Nong, no Vietnã, com os algoritmos RF, K-NN e SVM, e relataram a maior precisão por RF, com valores de Acurácia Geral e Índice Kappa de 80,0 e 80,2%, respectivamente, os mesmos recomendaram o classificador RF para classificação uso e cobertura da terra devido à facilidade na seleção de parâmetros em RF. O RF alcançou uma precisão maior do que o SVM usando dados do Sentinel-1 da Amazônia brasileira (CHAVES et al., 2020).

O algoritmo 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). Na Tabela 2 estão expostos os valores de Acurácia do Produtor (A.P) e Acurácia do Usuário (A.U) obtidos por este trabalho.

Tabela 2. Acurácia do Produtor e Acurácia do Usuário

| Classificador<br>Classe<br>Amostragem | RF          |        | MMD   |       | LibSVM |       | BAYES |       |
|---------------------------------------|-------------|--------|-------|-------|--------|-------|-------|-------|
|                                       | (A.U)       | (A.P)  | (A.U) | (A.P) | (A.U)  | (A.P) | (A.U) | (A.P) |
|                                       | -----%----- |        |       |       |        |       |       |       |
| Vegetação Densa                       | 99,34       | 100,00 | 78,02 | 57,42 | 92,65  | 95,70 | 89,60 | 36,96 |
| Corpos Hídricos                       | 100,00      | 100,00 | 40,79 | 74,54 | 94,33  | 90,90 | 48,58 | 93,63 |
| Solo Exposto                          | 99,53       | 99,06  | 87,27 | 66,97 | 86,48  | 74,41 | 55,98 | 54,41 |
| Semidensa                             | 98,73       | 98,31  | 72,48 | 78,57 | 75,76  | 82,77 | 53,84 | 47,05 |
| Rala Mais Solo Exposto                | 98,61       | 98,61  | 71,18 | 77,41 | 89,49  | 90,32 | 63,52 | 96,31 |

Legenda: (RF): Random Forest; (MMD): Minimum Distance – Euclidean; (LibSVM): Library for Support Vector Machines; (BAYES): Naive Bayes; A.P: Acurácia do Produtor; A.U: Acurácia do Usuário.



Pelos resultados obtidos (Tabela 2), observa-se que o classificador RF se destaca, apresentando valores de Acurácia do Produtor e Usuário de 98,31-100% e 98,61-100%, respectivamente.

Carvalho et al. (2021), ressaltam que isto representa que o algoritmo de classificação indicou 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.

O classificador BAYES demonstra que apenas 47,05% dos pixels da Classe semidensa apresentam-se fiel ao que o classificador realizou, enquanto que a Acurácia do Usuário apresenta apenas 53,84% dos pixels indicados.

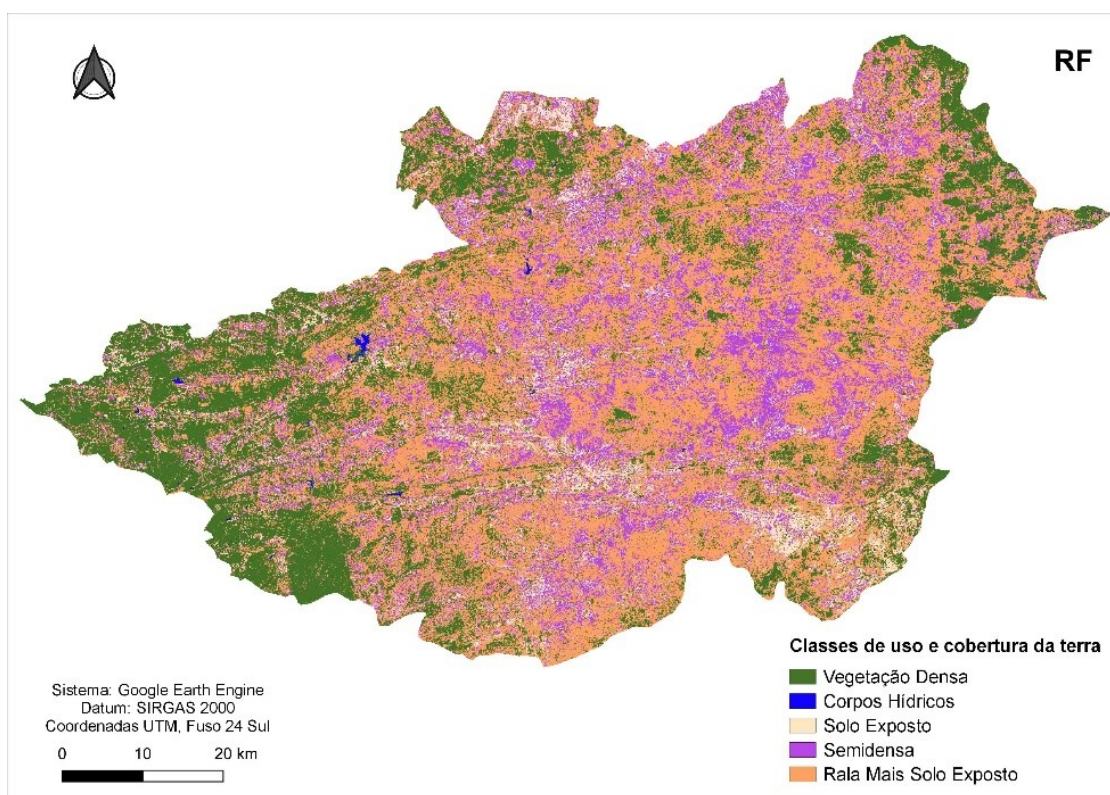
Silva (2019), executando o algoritmo RF no estudo sobre as mudanças de uso e cobertura da terra na região semiárida do nordeste do Brasil entre os anos 2000

a 2015, obteve os valores de Acurácia do Produtor de 82,36 a 99,86%, e Acurácia do Usuário entre 81,91 e 99,80%, valores estes referente à classe Água, o autor ainda ressalva que, as Acurácias para as demais coberturas da terra tiveram desempenhos satisfatórios, o que ratifica que o algoritmo RF é aplicável para classificação dos aspectos da paisagem em regiões semiáridas.

De acordo com a Tabela 1, é possível verificar que a classe Semidensa apresenta 48,24% da área total, seguido pela classe Vegetação Densa (26,86%), Rala Mais Solo Exposto (16,91%), Solo Exposto (7,70%) e Corpos Hídricos (0,29%), oriundo do classificador RF.

Conforme os dados da Tabela 1, e pela Figura 3 do mapa de uso e cobertura do solo referente ao algoritmo RF, mediante o ano de 2021, observa-se que a classe vegetação densa, distribuída em 152.228,07 ha, com percentual de 26,86%, apresenta declínio.

Figura 3. Mapa de uso e cobertura do solo referente ao classificador RF



Fonte: Adaptado de Google Earth Engine (2021)

Ao confrontar com a pesquisa exercida por Francisco et al. (2013), os autores obtiveram o percentual de 36,70% da área da bacia para o ano de 2003, mediante a classe vegetação densa. Essas áreas ocupam em grande parte, áreas de mais difícil acesso, de solos rasos e declivosos, fato constatado nos estudos sobre uso das terras no semiárido (PAES-SILVA et al., 2003; SOUZA et al., 2009; MELO et al., 2011; FRANCISCO et al., 2013). 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 (FRANCISCO et al., 2021).

Em estudo para a predição do uso e cobertura da terra na Bacia Hidrográfica do rio Taperoá para o ano de 2060, Silva et al. (2020), utilizando o algoritmo Multilayer Perceptron (MLP), disponível no software IDRISI TerrSet, obteve o percentual de 12,25%, para a classe vegetação densa. Autores como Seabra et al. (2014), salientam que a vegetação natural, são utilizadas em sua maioria como área de pastagem e ou retirada de lenha e fabricação de carvão vegetal, o que leva a devastação da vegetação original, deixando o solo desprotegido e favorecendo processos erosivos.

As áreas com menor vegetação na cobertura do solo, representado pela classe rala mais solo exposto, abrangem uma superfície de 95.837,53 ha, correspondente a 16,91% da área total da bacia que se disseminam no decorrer da drenagem. Nota-se uma diminuição nesta classe ao afrontar com a pesquisa de Francisco et al. (2013) que destacam um percentual de 28,60% desta classe. Francisco et al. (2021) e Cardoso et al. (2021), retratam que a vegetação nessas áreas é bastante antropizada em grandes áreas de solo exposto, como exploradas pela agricultura na região. Silva et al. (2020), obteve o percentual de 38,83% da área da bacia para o ano de 2060, mediante a classe rala mais solo exposto. As áreas utilizadas para classe semidensa compreende uma área de 273.427,68 ha, que corresponde a 48,24% da área total da bacia. Foi notado um aumento nesta classe, ao confrontar com Francisco et al. (2013), os mesmos ressaltaram que esta área representou 29,70% da área da bacia.

Segundo Silva et al. (2020), as principais alterações no uso e cobertura da terra de 2002 quando comparado com o ano de 1990 foi a diminuição da classe vegetação densa para semidensa. De acordo com Francisco et al. (2013), são áreas de pastejo para os animais, e estes padrões de vegetação ocupam posições intermediárias na paisagem, e normalmente ocorrem sobre solos mais rasos, inapropriados para agricultura devido as condições climáticas.

A classe solo exposto engloba uma área de 43.635,04 ha, que corresponde a 7,70% da área de estudo para o ano de 2021. Nota-se um aumento da classe solo exposto ao confrontar com o estudo de Francisco et al. (2013) que destacam um percentual de 1,0% da classe solo exposto, para o ano de 2013. A cobertura vegetal em extensas áreas da bacia do rio Taperoá apresenta-se bastante esparsa, com uma considerável área de solo exposto, correspondente às áreas urbanizadas e degradadas pela exploração mineral e uso inadequado do solo. Estas práticas estão causando um processo intenso de degradação gradativa da estrutura superficial da paisagem nesta região (PAIVA, 2009). Em estudo conduzido por Silva et al. (2020), com o propósito de prever a cobertura da terra para o ano de 2060, obteve o percentual de 25,68% da área da bacia, mediante a classe solo exposto.

A classe corpos hídricos abrangem uma área de 1.620,68 ha, que corresponde a 0,29% do total da bacia (Tabela 1). Francisco et al. (2013) e Cardoso et al. (2021), encontraram os percentuais de 0,6 e 1%, respectivamente para a classe corpos hídricos, composta em sua maioria por açudes. Mendonça e Danni-Oliveira (2007), enfatizam que o clima na área da bacia é caracterizado, por apresentar baixos índices pluviométricos, grande variabilidade e irregularidade na distribuição das chuvas, bem como elevadas temperaturas, assim com longos períodos de estiagem.

## Conclusão

Entre os quatro classificadores aplicados nesta pesquisa, os resultados obtidos pelo algoritmo baseado em árvore de decisão RF, foi bastante satisfatório e produziu boa precisão, com Índice Kappa 98,93%, Acurácia Geral 99,16%, Acurácia do Produtor 98,61 - 100% e Acurácia do Usuário 98,31 - 100%, apresentando o melhor desempenho. A plataforma do Google Earth Engine proporcionou um desempenho satisfatório no processamento computacional em larga escala, capaz de suportar diversas informações ambientais, como a prática de mapeamento de uso e cobertura da terra realizada neste estudo, propiciando o reconhecimento das alterações do uso e cobertura da terra.

## Agradecimentos

Ao CNPq pela concessão da bolsa ao autor.

## Referências Bibliográficas

- ALVARENGA, L. A.; MELLO, C. R.; COLOMBO, A.; CUARTAS, L. A.; BOWLING, L. C. Assessment of land cover change on the hydrology of a Brazilian headwater watershed using the Distributed Hydrology-Soil-Vegetation Model. *Catena*, v. 143, p. 7-17, 2016.
- AEDLA, R.; DWARAKISH, G. S.; REDDY, D. V. Keynote-III Advances in Digital Image Processing and Remote Sensing Techniques for Coastal Applications using Satellite Images. In: **Prosiding Seminar ACE**, 23, 2016, Indonésia. Anais... Indonésia, 2016.
- 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.
- CARDOSO, P. V.; SEABRA, V. S.; XAVIER, R. A., RODRIGUES, E. M.; GOMES, A. S. Mapeamento de Áreas de Caatinga Através do Random Forrest: Estudo de caso na Bacia do Rio Taperoá. *Revista Georaguia*, v. 11, p. 55-68, 2021.
- CHEMURA, A.; RWASOKA, D.; MUTANGA, O.; DUBE, T.; MUSHORE, T. The impact of land-use/land cover changes on water balance of the heterogeneous Buzi sub-catchment, Zimbabwe. *Remote Sensing Applications: Society and Environment*, v. 18, e100292, 2020.
- 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.
- 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.
- 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.
- 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.

- 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.
- DUVEILLER, G.; FORZIERI, G.; ROBERTSON, E.; LI, W.; GEORGIEVSKI, G.; LAWRENCE, P.; WILTSHIRE, A.; CIAIS, P.; PONGRATZ, J.; SITCH, S.; ARNETH, A.; CESCATTI, A. Biophysics and vegetation cover change: a process-based evaluation framework for confronting land surface models with satellite observations. **Earth System Science Data**, v. 10, n. 3, p. 1265-1279, 2018.
- DEVARAJU, N.; NOBLET-DUCOUDRÉ, N.; QUESADA, B.; BALA, G. Quantifying the relative importance of direct and indirect biophysical effects of deforestation on surface temperature and teleconnections. **Journal of Climate**, v. 31, n. 10, p. 3811-3829, 2018.
- DANTAS, J. C.; SILVA, M. A.; SILVA, R. M.; VIANNA, P. C. G. Simulação vazão-erosão usando o modelo SWAT para uma grande bacia da região semiárida da Paraíba. **Geociências**, v. 34, n. 4, p. 816-827, 2015.
- 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.
- FRANCISCO, P. R. M.; AYRES, G. D. J.; FARIAS, E. S. B.; MORAES NETO, J. M.; SILVA, V. F.; SANTOS, D.; OLIVEIRA, F. P. **Deteção 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. 1.a ed. Campina Grande: EPTEC, 2021. 193p.
- FRANCISCO, P. R. M.; CHAVES, I. B.; LIMA, E. R. V. Mapeamento das terras para mecanização agrícola-Estado da Paraíba. **Revista Brasileira de Geografia Física**, v. 5, n. 2, p. 233-249, 2012a.
- FRANCISCO, P. R. M.; CHAVES, I. B.; CHAVES, L. H. G.; LIMA, E. R. V. Detecção de mudança da vegetação de caatinga. **Revista Brasileira de Geografia Física**, v. 5, n. 6, p. 1473-1487, 2012b.
- 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.
- FRANCISCO, P. R. M.; CHAVES, I. D. B.; CHAVES, L. H. G.; BRANDÃO, Z. N.; LIMA, E. D.; SILVA, B. D. Mapeamento da vulnerabilidade das terras da bacia hidrográfica do Rio Taperoá. **Revista Brasileira de Geografia Física**, v. 6, n. 02, p. 271-286, 2013.
- FREITAS, M. S.; NETO, J. B. F.; TAVARES, K. S. R. Análise Temporal das Mudanças do Uso e Cobertura da Terra na Bacia Hidrográfica do Córrego Água Limpa em São João Del Rei - MG. In: **Workshop Internacional sobre Planejamento e Desenvolvimento Sustentável em Bacias Hidrográficas**, 8, 2021, Goiânia. Anais... Goiânia, 2021.
- GHEBREZGABHER, M. G.; YANG, T.; YANG, X.; WANG, X.; KHAN, M. Extracting and analyzing forest and woodland cover change in Eritrea based on LANDSAT data using supervised classification. **The Egyptian Journal of Remote Sensing and Space Science**, v. 19, n. 1, p. 37-47, 2016.
- GU, X.; LONG, A.; LIU, G.; YU, J.; WANG, H.; YANG, Y.; ZHANG, P. Changes in ecosystem service value in the 1 km lakeshore zone of Poyang Lake from 1980 to 2020. **Land**, v. 10, n. 9, e951, 2021.
- GHOORBANIAN, A.; KAKOOEI, M.; AMANI, M.; MAHDAVI, S.; MOHAMMADZADEH, A.; HASANLOU, M. Improved land cover map of Iran using Sentinel imagery within Google Earth Engine and a novel automatic workflow for land cover classification using migrated training samples. **Journal of Photogrammetry and Remote Sensing**, v. 167, p. 276-288, 2020.
- GOOGLE EARTH ENGINE. **A planetary-scale platform for Earth Science Data & Analysis**. 2021. Disponível em: <<https://earthengine.google.com/>>. Acesso em: 25 de abril de 2023.
- 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.
- KOTHARI, N. S.; MEHER, S. K. Semisupervised classification of remote sensing images using efficient neighborhood learning method. **Engineering Applications of Artificial Intelligence**, v. 90, e103520, 2020.
- KOLLI, M. K.; OPP, C.; KARTHE, D.; GROLL, M. Mapping of major land-use changes in the Kolleru Lake freshwater ecosystem by using LANDSAT satellite images in Google Earth Engine. **Water**, v. 12, n. 9, e2493, 2020.
- LI, Q.; QIU, C.; MA, L.; SCHMITT, M.; ZHU, X. X. Mapping the land cover of Africa at 10 m resolution from multi-source remote sensing data with Google Earth Engine. **Remote Sensing**, v. 12, n. 4, e602, 2020.
- LI, X.; MESSINA, J. P.; MOORE, N. J.; FAN, P.; SHORTRIDGE, A. M. MODIS land cover uncertainty in regional climate simulations. **Climate Dynamics**, v. 49, n. 11-12, p. 4047-4059, 2017.
- 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.
- LIU, X.; HE, J.; YAO, Y.; ZHANG, J.; LIANG, H.; WANG, H.; HONG, Y. Classifying urban land use by integrating remote sensing and social media data. **International Journal of Geographical Information Science**, v. 31, n. 8, p. 1675-1696, 2017.
- LOWE, B.; KULKARNI, A. Multispectral Image Analysis Using Random Forest. **International Journal on Soft Computing**, v. 6, n. 1, p. 1-14, 2015.
- MELO, E. T.; SALES, M. C. L.; OLIVEIRA, J. G. B. Aplicação do Índice de Vegetação por Diferença Normalizada (NDVI) para análise da degradação ambiental da microbacia hidrográfica do Riacho dos Cavalos, Cratêus-CE. **RA'EGA**, v. 23, p. 520-533, 2011.
- 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.
- MENDONÇA, F.; DANNI-OLIVEIRA, I. M. **Climatologia: noções básicas e climas do Brasil**. São Paulo: Oficina de Textos, 2007. 208p.
- NGUYEN, H. T. T.; DOAN, T. M.; TOMPPÖ, E.; McROBERTS, R. E. Land Use/land cover mapping using multitemporal Sentinel-2 imagery and four classification methods - A case study from Dak Nong, Vietnam. **Remote Sensing**, v. 12, n. 9, e1367, 2020.
- 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.
- NYBERG, G.; KNUTSSON, P.; OSTWALD, M.; ÖBORN, I.; WREDLE, E.; OTIENO, D. J.; MUREITHI, S.; MWANGI, P.; SAID, M. Y.; JIRSTRÖM, M.; GRÖNVALL, A.; WERNERSSON, J.; SVANLUND, S.; SAXER, L.; GEUTJES, L.; KARMEBÄCK, V.; WAIRORE, J. N.; WAMBUI, R.; LEEUW, J. D.; MALMER, A. Enclosures in West Pokot, Kenya: Transforming land, livestock and livelihoods in drylands. **Pastoralism**, v. 5, n. 1, p. 1-12, 2015.
- OLOFSSON, P.; FOODY, G. M.; HEROLD, M.; STEHMAN, S. V.; WOODCOCK, C. E.; WULDER, M. A. Good practices for estimating area and assessing accuracy of land change. **Remote Sensing of Environment**, v. 148, p. 42-57, 2014.
- PAIVA, L. A. N.; SILVA, F. M.; NASCIMENTO, P. S. R. Uso de imagens MODIS e TM para a detecção de áreas degradadas na sub-bacia do Taperoá-PB. In: **Simpósio Brasileiro de Geografia Física Aplicada**, 13, 2009. Viçosa. Anais... Viçosa, 2009.



- RIMAL, B.; SHARMA, R.; KUNWAR, R.; KESHTKAR, H.; STORK, N. E.; RIJAL, S.; RAHMAN, S. A.; BARAL, H. Effects of land use and land cover change on ecosystem services in the Koshi River Basin, Eastern Nepal. **Ecosystem Services**, v. 38, e100963, 2019.
- SALOVAARA, K. J.; THESSLER, S.; MALIK, R. N.; TUOMISTO, H. Classification of Amazonian primary rain forest vegetation using Landsat ETM+ satellite imagery. **Remote Sensing of Environment**, v. 97, n. 1, p. 39-51, 2005.
- SANTOS, C. J. D. S.; MONTEIRO, G. N.; CRUZ, K. K. S.; SOUZA, J. O. P. Caracterização das unidades de paisagens na bacia hidrográfica do rio Taperoá-PB. **Revista GeoUECE**, v. 8, n. 15, p. 137-149, 2019.
- SEABRA, V.; XAVIER, R. A.; DAMASCENO, J.; DORNELLAS, P. D. C. Mapeamento do uso e cobertura do solo da bacia do rio Taperoá: região semiárida do Estado da Paraíba. **Caminhos de Geografia**, v. 15, n. 50, p. 127-137, 2014.
- SILVA, J. P. F. **Vulnerabilidade ambiental às mudanças de uso e cobertura da terra na região semiárida do nordeste do Brasil**. 168f. Tese (Doutorado em Ciências Florestais). Universidade Federal Rural de Pernambuco. Recife, 2019.
- SOUZA, B. I.; SUERTEGARAY, D. M. A.; LIMA, E. R. V. Desertificação e seus efeitos na vegetação e solos do Cariri Paraibano. **Mercator**, v. 8, n. 16, p. 217-232, 2009.
- SILVA, L. P.; XAVIER, A. P. C.; SILVA, R. M.; SANTOS, C. A. G. Modeling land cover change based on an artificial neural network for a semiarid river basin in northeastern Brazil. **Global Ecology and Conservation**, v. 21, e00811, 2020.
- SILVA, R. G.; JUVANHOL, R. S.; SANTOS, A. R. Mapeamento de Fragmentos Florestais por meio de Técnica de Mineração de Dados. In: **Simpósio Brasileiro de Sensoriamento Remoto**, 19, 2020. Santos, Anais... Santos, 2020.
- SOUZA, B. I.; SILANS, A. M. P. B.; SANTOS, J. B. Contribuição ao estudo da desertificação na Bacia do Taperoá. **Revista Brasileira de Engenharia Agrícola e Ambiental**, v. 8, n. 2-3, p. 292-298, 2004.
- STEHMAN, S. V.; FOODY, G. M. Key issues in rigorous accuracy assessment of land cover products. **Remote Sensing of Environment**, v. 231, e111199, 2019.
- STEINHAUSEN, M. J.; WAGNER, P. D.; NARASIMHAN, B.; WASKE, B. Combining Sentinel-1 and Sentinel-2 data for improved land use and land cover mapping of monsoon regions. **International Journal of Applied Earth Observation and Geoinformation**, v. 73, p. 595-604, 2018.
- TANG, H. J.; WU, W. B.; YANG, P.; CHEN, Y. Q.; VERBURG, P. H. Recent progresses of land use and land cover change (LUCC) models. **Acta Geographica Sinica**, v. 64, n. 4, p. 456-468, 2009.
- 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.
- WINCKLER, J.; REICK, C. H.; LUYSSAERT, S.; CESCATTI, A.; STOY, P. C.; LEJEUNE, Q.; RADDATZ, T.; CHLOND, A.; HEIDKAMP, M.; PONGRATZ, J. Different response of surface temperature and air temperature to deforestation in climate models. **Earth System Dynamics**, v. 10, n. 3, p. 473-484, 2019.
- WAGNER, P. D.; BHALLAMUDI, S. M.; NARASIMHAN, B.; KUMAR, S.; FOHRER, N.; FIENER, P. Comparing the effects of dynamic versus static representations of land use change in hydrologic impact assessments. **Environmental Modelling & Software**, v. 122, e103987, 2019.
- ZHANG, C.; SARGENT, I.; PAN, X.; LI, H.; GARDINER, A.; HARE, J.; ATKINSON, P. M. Joint Deep Learning for land cover and land use classification. **Remote Sensing of Environment**, v. 221, p. 173-187, 2019.
- 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, p. 175-185, 2018.