

SENSORIAMENTO REMOTO E MACHINE LEARNING APLICADOS AO MAPEAMENTO E CLASSIFICAÇÃO DO USO E COBERTURA DA TERRA EM TRÊS CIDADES INSERIDAS NO BIOMA CAATINGA, NA MICRORREGIÃO VALE DO AÇU, RIO GRANDE DO NORTE

Anselmo Manoel dos Santos¹

Gabrielle Oliveira²

Kátia Alves Arraes³

Melquisedec Medeiros Moreira⁴

RESUMO

Compreender o uso e cobertura da terra é essencial para o planejamento territorial eficiente e sustentável. O presente estudo avaliou a dinâmica de uso e cobertura da terra em três municípios da microrregião do Vale do Açu, Rio Grande do Norte, utilizando geotecnologias. Foram analisadas imagens do satélite Sentinel-2, do dia de 24 de setembro de 2021. A classificação do uso e cobertura da terra foi realizada por meio de aprendizado de máquina com o modelo *Random Forest*, em abordagem supervisionada orientada a objetos. Os resultados indicaram que a vegetação nativa ainda predomina na região, exceto em Porto do Mangue, onde há maior presença de áreas agrícolas. A intensificação das atividades humanas, especialmente agrícolas, está diretamente relacionada às mudanças na cobertura da terra, evidenciando a importância do monitoramento para o planejamento territorial sustentável.

PALAVRAS-CHAVE: Sensoriamento Remoto. Uso e ocupação da terra. *Machine Learning*.

REMOTE SENSING AND MACHINE LEARNING APPLIED TO THE MAPPING AND CLASSIFICATION OF LAND USE AND LAND COVER IN THREE CITIES WITHIN THE CAATINGA BIOME, IN THE VALE DO AÇU MICROREGION, RIO GRANDE DO NORTE

ABSTRACT

Understanding land use and land cover is essential for efficient and sustainable territorial planning. This study evaluated the dynamics of land use and land cover in three municipalities of the Açu Valley microregion, in Rio Grande do Norte, using geotechnologies. Images from the Sentinel-2 satellite, dated September 24, 2021, were analyzed. The land use and land cover classification was performed using machine learning with the Random Forest model, in a supervised object-oriented approach. The results indicated that native vegetation still predominates in the region, except in Porto do Mangue, where there is a greater presence of agricultural areas. The intensification of human activities, especially agriculture, is directly related to changes in land cover, highlighting the importance of monitoring for sustainable territorial planning.

¹Mestre pela UFAL, Instituto Nacional de Pesquisas Espaciais - INPE, Email: anselmo.icat.ufal@gmail.com

²Doutora pela UFCG, Instituto Nacional de Pesquisas Espaciais - INPE, Email: gabiboliveira121@gmail.com

³Mestra pela UFF, Instituto Nacional de Pesquisas Espaciais - INPE, Email: katia.arraes@inpe.br

⁴Doutor pela UnB, Instituto Nacional de Pesquisas Espaciais - INPE, Email: melquisedec.moreira@inpe.br

KEYWORDS: Remote Sensing. Land Use and Land Cover. Machine Learning.

SENSORIAMIENTO REMOTO Y MACHINE LEARNING APLICADOS AL MAPEO Y CLASIFICACIÓN DEL USO Y COBERTURA DEL SUELO EN TRES CIUDADES UBICADAS EN EL BIOMA CAATINGA, EN LA MICRORREGIÓN VALE DO AÇU, RIO GRANDE DO NORTE

RESUMEM

Comprender el uso y la cobertura del suelo es esencial para una planificación territorial eficiente y sostenible. El presente estudio evaluó la dinámica del uso y la cobertura del suelo en tres municipios de la microrregión del Valle de Açu, en Rio Grande do Norte, utilizando geotecnologías. Se analizaron imágenes del satélite Sentinel-2, con fecha del 24 de septiembre de 2021. La clasificación del uso y la cobertura del suelo se realizó mediante aprendizaje automático con el modelo Random Forest, en un enfoque supervisado y orientado a objetos. Los resultados indicaron que la vegetación nativa aún predomina en la región, excepto en Porto do Mangue, donde hay una mayor presencia de áreas agrícolas. La intensificación de las actividades humanas, especialmente las agrícolas, está directamente relacionada con los cambios en la cobertura del suelo, lo que evidencia la importancia del monitoreo para la planificación territorial sostenible.

PALABRAS-CLAVE: Sensoriamento Remoto. Uso y Ocupación del Suelo. Aprendizaje Automático.

INTRODUÇÃO

O bioma Caatinga está inserido no Polígono das Secas, atualmente conhecido como Semiárido Brasileiro (SAB), região caracterizada por baixos índices pluviométricos (Carvalho, 2015), e que pertence, em sua grande porção, à região Nordeste do Brasil (NEB). A Caatinga, conforme declaração do Instituto Nacional do Semiárido (INSA, 2020), é um bioma composto, em grande totalidade, por espécies de plantas arbustivas, que tem características fisiológicas adaptadas ao clima semiárido, qualidade na qual, a variação da densidade florística ao longo do ano responde diretamente à incidência de chuvas.

A atividade agroeconômica local mais representativa deste bioma é a agricultura de subsistência, pecuária, e em menor quantidade a agroindústria. Ao contrário dos demais biomas de zonas áridas e semiáridas do mundo, a Caatinga se destaca pelo fato de ser uma região de grandes números de produtores rurais, com destaque os que cultivam variedades de produtos agrícolas de abrangência

regional e, em alguns casos, nacional e internacional (Embrapa Territorial, 2022).

Como relataram Campos *et al.*, (2015), predominam dois sistemas de cultivo agrícolas no referido bioma, a agricultura de sequeiro e a agricultura irrigada. Ainda de acordo com Campos *et al.* (2015), a agricultura de sequeiro é predominante na Caatinga, utilizada principalmente por pequenos agricultores. Por sua vez, a agricultura irrigada ocupa uma área de 250 mil ha, utilizada principalmente para a produção de frutas em larga escala. Mesmo sendo eficaz para produção em grande escala de produtos agrícolas, a irrigação artificial, ao mesmo tempo que traz benefícios para a produção de insumos agrícolas, paralelamente é considerada um fator que contribui para agravar a escassez dos recursos hídricos.

Além disso, nas últimas décadas houve uma expansão da agroindústria no bioma Caatinga, o que incentivou o desenvolvimento socioeconômico na região, porém, de certa forma, tais mudanças impuseram novos problemas no uso e cobertura da terra, principalmente no desflorestamento das espécies nativas do bioma Caatinga (Alves *et al.*, 2009).

A expansão territorial não planejada da agroindústria na Caatinga acarreta mudanças significativas no uso e cobertura da terra e impacta negativamente os principais aspectos do funcionamento do sistema terrestre, no que se refere ao balanço de energia e interação da vegetação, sistemas atmosféricos e ambiental (como por exemplo regime de chuvas e anomalias de temperatura), de escala regional e microrregional. Entretanto, para Lambin, Geist e Lepers (2003) destacaram que nem todas as modificações na cobertura e uso da terra são negativas, uma vez que muitas formas de uso no solo no bioma caatinga, bem como a mudança na cobertura terrestre para práticas agrícolas está associada aos aumentos da produção de alimentos.

Desta forma, a compreensão da dinâmica do Uso e Ocupação da terra (UOS) é fundamental para mensurar espacialmente as modificações, características e composição da superfície terrestre, como também, avaliar os impactos nos ambientes naturais decorrentes das atividades humanas ou ação natural, além de proporcionar o entendimento das tipologias biofísicas que compõem o bioma Caatinga (DUTRA *et al.*, 2020; RODRIGUES *et al.*, 2022).

O mapeamento do uso e cobertura da terra com uso de ferramentas computacionais e geoespaciais vem sendo realizado nas últimas décadas por meio da utilização de tecnologias sensoriais, como sensores passivos e ativos acoplados em satélites geoestacionário e de órbita polar. Nesta área, Florenzano (2007) enfatizou que o sensoriamento remoto é um conjunto de técnicas científicas que proporciona estudar áreas remotas de pequenas, médias e grandes escalas espaciais.

A microrregião do Vale do Açu-RN faz parte dos polos agroindustriais da região do semiárido brasileiro, criado em 1998, através do Subprograma Polos de Desenvolvimento Integrado do Nordeste,

instituído em 1996, pelo Programa de Apoio e Desenvolvimento da Fruticultura Irrigada do Nordeste, sob a responsabilidade do Ministério da Agricultura Pecuária e do Abastecimento (Mapa, 2008).

Com base no exposto, esse estudo tem fundamento, dado a importância e necessidade de compreender as características espaciais do uso e ocupação da terra no bioma Caatinga em três municípios da região do Vale do Açu-RN, no sentido de contribuir para o planejamento estratégico e ações que visem o desenvolvimento sustentável, práticas e manejo no solo não agressivo ao meio ambiente. Adicionalmente, este estudo poderá contribuir para a identificação e controle do potencial do desflorestamento do bioma Caatinga, ocasionado pela expansão da agricultura ao longo dos próximos anos.

Por este motivo, os municípios de Alto do Rodrigues, Jucurutu e Porto do Mangue foram escolhidos para serem objetos desse estudo por estarem inseridos em importantes e diversificados polos de produção, que vai desde a área com potencial agrícola, pecuária e carcinicultura, sendo, no entanto, cidades estratégicas para economia dessa região, assim como também para o estado do Rio Grande do Norte.

A hipótese desta pesquisa é que o uso integrado de sensoriamento remoto e técnicas de *machine learning* permitem mapear e classificar com precisão as diferentes classes de uso e cobertura da terra nas três cidades analisadas, revelando que a substituição da vegetação nativa do bioma Caatinga está associada à expansão das atividades agrícolas mecanizadas na microrregião do Vale do Açu, no Rio Grande do Norte.

Esse trabalho busca responder a seguinte pergunta norteadora: De que maneira o uso de sensoriamento remoto aliado a técnicas de *machine learning* pode contribuir para identificar, mapear e classificar as alterações no uso e cobertura da terra em áreas do bioma Caatinga na microrregião do Vale do Açu, no Rio Grande do Norte?

O objetivo do estudo é analisar o uso e cobertura da terra nas cidades de Alto do Rodrigues, Jucurutu e Porto do Mangue, inseridas na microrregião do Vale do Açu, Rio Grande do Norte, por meio das aplicações de geotecnologias e *Machine Learning*, com intuito de contribuindo para o fomento de políticas públicas voltadas às demandas da agricultura e proteção do bioma Caatinga.


Caracterização da Área de Estudo

A microrregião do Vale do Açu, Rio Grande do Norte-RN (Figura 1), é constituída por nove municípios: Alto do Rodrigues, Assú, Carnaúbas, Ipanguaçu, Itajá, Jucurutu, Pendências, Porto do Mangue e São Rafael. Essa microrregião está situada nas coordenadas geográficas latitude 5° 34' 37"

sul e longitude $36^{\circ} 54' 32''$ oeste, e compreendem uma área, de acordo com o Instituto Brasileiro de Geografia e Estatística (IBGE), de $4.773,35 \text{ km}^2$ (Ibge, 2022).

O Vale do Açu é uma das regiões do estado do Rio Grande do Norte com maior potencial para a atividade produtiva relacionada à agricultura, seja para pequenos produtores ou para a instalação de grandes polos agroindustriais. Um dos motivos para esse potencial agrícola é a sua disponibilidade de recursos hídricos, e por ser uma região que tem índice pluviométrico acima da média das regiões circunvizinhas, o que potencializa como uma zona territorial propícia à agricultura.

Figura 1 - Microrregião do Vale do Açu-RN e respectivos municípios trabalhados, destacados com hachuras em cor cinza




Fonte: Elaborado pelos autores (2025)

Os municípios destacados na Figura 1 apresentam distintas características geográficas e demográficas. Alto do Rodrigues (Figura 2-A) está situado na latitude $-5^{\circ} 17' 16''$ Sul e longitude $-36^{\circ} 45' 43''$, a uma altitude média de 82 metros, com área territorial de $191,334 \text{ km}^2$. Em 2021, sua população estimada era de 14.923 habitantes, resultando em uma densidade demográfica de 78 hab./km 2 . O município de Jucurutu (Figura 2-B), por sua vez, localiza-se na latitude $-6^{\circ} 02' 02''$ Sul e longitude $-37^{\circ} 01' 12''$, a uma altitude média de 63 metros. Sua área territorial é de $933,73 \text{ km}^2$, com população estimada

em 18.335 habitantes e densidade demográfica de 19,6 hab./km². Porto do Mangue (Figura 2-C), situado na latitude -5° 04' 04" Sul e longitude -36° 46' 55", possui altitude média de 3 metros, área de 319 km², população estimada de 6.437 habitantes e densidade de 17,5 hab./km² (Ibge, 2021).

Figura 2 - Extensão territorial dos municípios Alto do Rodrigues (A), Jucurutu (B) e Porto do Mangue (C)



Fonte: Elaborado pelos autores (2025)

O clima predominante na microrregião é o semiárido, caracterizado por temperaturas médias anuais em torno de 27°C e baixos índices pluviométricos, variando entre 400 e 600 milímetros por ano (Araújo Filho *et al.*, 2019; Mutti *et al.*, 2020). Essa condição climática impõe desafios à agricultura local, tornando a irrigação uma prática essencial para a produção agrícola. A vegetação típica é a Caatinga, adaptada às condições de seca e composta por espécies resistentes à aridez. Apesar das adversidades climáticas, a região tem se destacado na produção de frutas irrigadas, como melão e mamão, destinadas tanto ao mercado interno quanto à exportação, evidenciando a importância da gestão sustentável dos recursos hídricos para o desenvolvimento econômico local (Dantas, 2021).

MATERIAIS E MÉTODOS

Ferramentas Computacionais Utilizadas

Foi utilizada a plataforma de processamento de dados geoespaciais em nuvem, *Google Earth Engine Code* (<https://code.earthengine.google.com>), que, de acordo com Kumar e Mutanga (2018), é uma ferramenta computacional de processamento de dados de alto desempenho baseada em linguagem Java script.

Foi utilizado também, o *software* QGIS v. 3.28 (<https://qgis.org/download>), cujo *software* possui aplicabilidade nos Sistemas de Informações Geográficas (GIS) de código aberto. O QGIS é um projeto oficial da *Open Source Geospatial Foundation* (OSGeo). A principal função é o processamento de dados vetoriais, do tipo *shapefile* e dados *raster*, como imagens de satélites. Nesse trabalho, o QGIS foi utilizado para confecção de mapas a partir de dados de satélites pós-processados.

Dados Geoespaciais: Satélite Sentinel-2

Foram utilizados para a classificação do uso e cobertura da terra, dados espectrais oriundos do satélite Sentinel-2, do projeto Copernicus, administrado pela Agência Espacial Europeia (ESA). A escolha da utilização dos dados do Sentinel-2, foi devido a sua resolução espacial, de 10 metros, o que resulta em resultados com melhor acurácia, conforme já foi evidenciado por Tassi e Vizzari (2020).

O satélite Sentinel-2, carrega a bordo o sensor multiespectral MSI, dispondo de 13 bandas espectrais entre as faixas de 490 a 1.375 nm , sendo 4 bandas com resolução espacial de 10 metros, 6 bandas com 20 metros e 3 bandas com 60 metros. Em relação ao espectro eletromagnético, o Sentinel 2 possui 4 bandas no infravermelho, 6 no visível e 3 bandas destinadas a correção atmosféricas, conforme Tabela 1.

Tabela 1 - Características das bandas espectrais do satélite Sentinel 2 utilizadas no processo de classificação e uso da terra.

Resolução	Nº de Bandas	Nome da banda	Comprimento de onda	Fusão de bandas
10 m	B4	<i>Red</i>	665	Cor verdadeira RGB (4 + 3 +2)
	B3	<i>Green</i>	560	
	B2	<i>Blue</i>	490	Falsa cor 1 e 2 RGB (8 + 4 +3) e (4 + 8 +3)
	B8	NIR (Infravermelho Próximo)	842	

Fonte: Adaptado de EngenSat (2016)

As principais aplicações dos dados coletados pelo Sentinel-2 estão destinadas para o monitoramento da agricultura, florestas, águas continentais, zonas costeiras, desastres naturais e uso e ocupação da terra. No entanto, para este trabalho, o Sentinel-2, conforme descrito na literatura, é considerado um dos satélites com melhor aplicabilidade para a classificação do uso e cobertura da terra.

Bandas Espectrais Auxiliares e Índices de Vegetação

O cálculo dos índices espectrais, o Índice de Vegetação por Diferença Normalizada (NDVI), derivado das bandas do infravermelho próximo (B8) e vermelho (B4), é empregado ao script para

mapear áreas vegetadas, pois, esse índice tem respostas distintas a depender da quantidade de água contida na vegetação, o que corresponde diretamente se a biomassa presente no solo tem pouca ou muita clorofila. O NDVI foi incorporado como bandas adicionais na imagem, que passa a conter as bandas originais selecionadas e as derivadas.

No contexto do script apresentado, o NDVI desempenha papel complementar e fundamental para aumentar a precisão da classificação do uso e ocupação da terra, pois realçam alvos distintos presentes na superfície terrestre.

Para a etapa de classificação, são carregados dois conjuntos de pontos vetoriais, amostras de treinamento (representando as classes de uso e cobertura: área urbana, solo exposto, vegetação densa, vegetação aberta, área agrícola e corpos d'água) e amostras de validação correspondentes. As amostras de treinamento são utilizadas para extrair os valores das bandas (B4, B3, B2, NDVI) e treinar um classificador *Random Forest* com 10 árvores de decisão. O classificador treinado é então aplicado à imagem para gerar o mapa classificado de uso e ocupação da terra, exibido diferenciada por classe.

Procedimento Utilizado para a Classificação do Uso e Cobertura da terra

Inicialmente, a região de interesse foi definida a partir de um *shapefile*, contendo os limites da microrregião do Vale do Açu, conforme está sendo detalhado na Figura 3. Após finalizado a configuração da delimitação da área de interesse, foi iniciada a busca dos dados na plataforma Google Engine Code (GEE), a qual foi realizada de forma automática, e todo processo de busca das imagens de satélite é realizada em “nuvem”.

Após a definição da região de interesse a variável contendo o polígono da cidade estudada, sendo uma de cada vez. A partir daí é impressa no console da interface do GEE, com a finalidade de permitir a inspeção visual da feição carregada, garantindo sua correta identificação e localização espacial. Na sequência, sobre essa estrutura foi vetorizado a geometria da área de estudo utilizando a função *.paint()*, que permite desenhar os contornos dos municípios.

As imagens de satélite utilizadas nas análises foram extraídas diretamente do catálogo armazenado em nuvem, sem a necessidade de *download* e armazenamento local. O repositório do Sentinel-2, mantido pela Agência Espacial Europeia (ESA) e integrado à infraestrutura do GEE, disponibiliza imagens multiespectrais em tempo quase real. A extração dessas imagens ocorre por meio de chamadas diretas ao catálogo de dados hospedado na nuvem do Google diretamente na interface do editor de script do GEE, através da função *ee.FeatureCollection()* e *.filter(ee.Filter.eq())*. Essa função

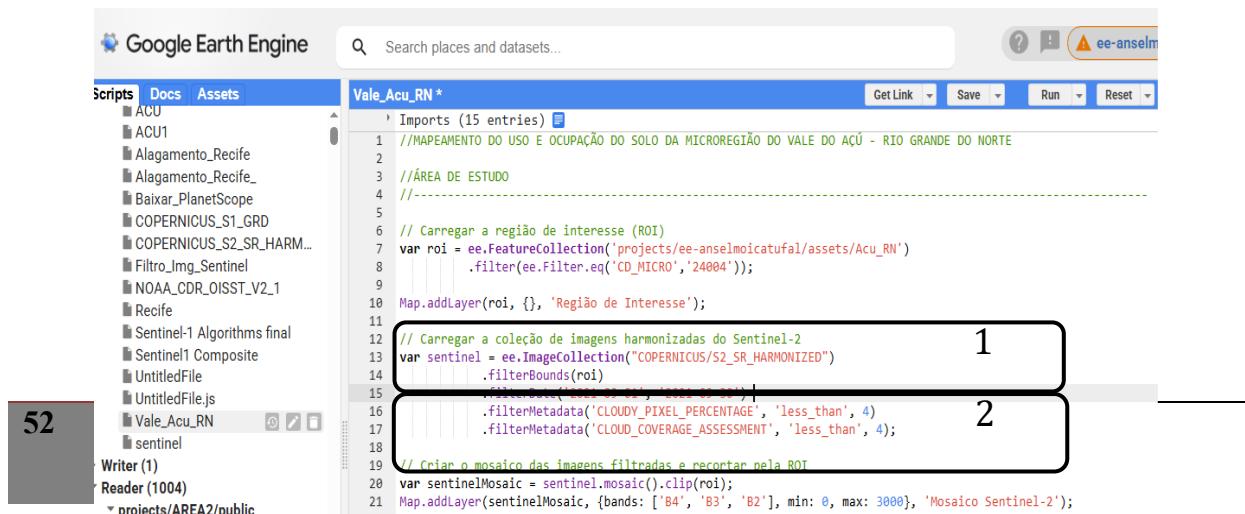
permitiu acessar séries temporais e mosaicos compostos sem a necessidade de lidar com grandes volumes de dados brutos. Essa abordagem favoreceu a eficiência computacional, reduzindo o tempo de processamento e ao acesso a imagens já ortorretificadas e calibradas radiometricamente.

Em seguida, imagens harmonizadas do sensor Sentinel-2, que se refere a um conjunto de dados que combina informações de distintas assinaturas espectrais para fornecer um detalhamento mais realístico da superfície terrestre. Essa abordagem é particularmente útil para superar limitações como a cobertura de nuvens, ou ainda facilitar os ajustes utilizando combinações de dois ou mais comprimentos de ondas.

Para tanto, foram selecionadas com base em critérios predefinidos, tal como ajustes em relação a cobertura de nuvens contidos na imagem, neste caso foi definido 4% de cobertura de nuvem nas imagens selecionadas. Esse procedimento foi essencial para delimitar a área de estudo e garantir a qualidade das imagens utilizadas na classificação supervisionada. Outra medida estabelecida se refere a escolha do mês do ano, no intuito de evitar influência em relação a estação chuvosa da região, que neste caso, compreende entre os meses de fevereiro a maio. Por tanto, foi estabelecido o mês de setembro, que é um período de transição entre a estação úmida e antecede a estação seca.

Inicialmente, aplicou-se um filtro espacial com base na região de interesse definido pela variável *roi*, por meio da função *filterBounds()*, detalhado na Figura - 3 (1). Em seguida, delimitou-se o intervalo temporal entre 01 a 30 de setembro de 2021, utilizando a função *filterDate()*. Posteriormente, foram implementados dois critérios adicionais de qualidade das imagens com base em metadados, porcentagem de pixel (*Cloudy_Pixel_Percentage*) e a avaliação da cobertura de nuvens (*Cloud_Coverage_Assessment*), ambos contendo valores de 4%, Figura - 3 (2). Esses filtros garantem a seleção de imagens com baixa interferência de nuvens, otimizando a acurácia da análise de uso e cobertura da terra. Com base nos critérios pré-configurados no script, a imagem que mais satisfez ao critério estabelecido, foi a do dia 24 de setembro de 2021.

Figura 3 - Trecho do código implementado na plataforma *Google Earth Engine Code* para carregar a região de interesse e catalogação dos dados correspondente à microrregião do Vale do Açu – RN e aplicação dos filtros.



The screenshot shows the Google Earth Engine Code editor interface. The left sidebar lists scripts, docs, and assets. The main area shows the script 'Vale_Acu_RN' with the following code:

```
//MAPEAMENTO DO USO E OCUPAÇÃO DO SOLO DA MICROREGIÃO DO VALE DO AÇU - RIO GRANDE DO NORTE
//ÁREA DE ESTUDO
//-
// Carregar a região de interesse (ROI)
var roi = ee.FeatureCollection('projects/ee-anselmoicatufal/assets/Acu_RN')
  .filter(ee.Filter.eq('CD_MICRO', '24004'));

Map.addLayer(roi, {}, 'Região de Interesse');

// Carregar a coleção de imagens harmonizadas do Sentinel-2
var sentinel = ee.ImageCollection("COPERNICUS/S2_SR_HARMONIZED")
  .filterBounds(roi)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less_than', 4)
  .filterMetadata('CLOUD_COVERAGE_ASSESSMENT', 'less_than', 4);

// Criar o mosaico das imagens filtradas e reportar na ROI
var sentinelMosaic = sentinel.mosaic().clip(roi);
Map.addLayer(sentinelMosaic, {bands: ['B4', 'B3', 'B2'], min: 0, max: 3000}, 'Mosaico Sentinel-2');
```

The code is annotated with two boxes: box 1 highlights the ROI loading and filterBounds() application, and box 2 highlights the filterMetadata() application for Cloudy Pixel Percentage and Cloud Coverage Assessment.

Fonte: Elaborado pelos autores (2025)

Na fase de seleção dos dados a ser trabalhado, foi importante observar o intervalo de tempo, a plataforma retorna uma série de imagens, a partir de então, é preciso selecionar a imagem com a menor cobertura de nuvens possível, como foi relatado acima. Vale mencionar que as imagens foram selecionadas no período de estiagem, que para a região estudada compreende os meses de julho a outubro. Para esta pesquisa foi selecionada a imagem do dia 24 de setembro de 2021.

Após essa etapa, foram coletados pontos de amostragem representativos de seis classes temáticas: área urbana, solo exposto, vegetação densa, vegetação aberta, área agrícola e corpos d'água. Os pontos foram divididos em conjuntos de treinamento e validação. As classes temáticas utilizadas como alvos da classificação, compreendem 6 tipos de diversos alvos, conforme mostrado na Tabela 2.

Tabela 2 - Classes temáticas utilizadas para a classificação

Classes temáticas	Características
Área urbana	Área com aglomeração de edificações. Área urbanizada.
Solo exposto	Áreas com solo descoberto.
Vegetação densa	Área com árvores e/ou arbustos que apresentam uma alta densidade de suas copas.
Vegetação aberta	As árvores e/ou arbustos apresentam-se espaçados, sendo possível a visualização da terra e/ou vegetação do estrato herbáceo.
Uso agrícola/Pastagem	Áreas com presença de vegetação antrópica cultivada. Em grande medida esta classe compreende o cultivo permanente de cajueiros comuns e/ou anões.
Corpos d'água	São áreas que compreende um curso d'água, trecho de rio, reservatório artificial ou natural, lago ou lagoa.

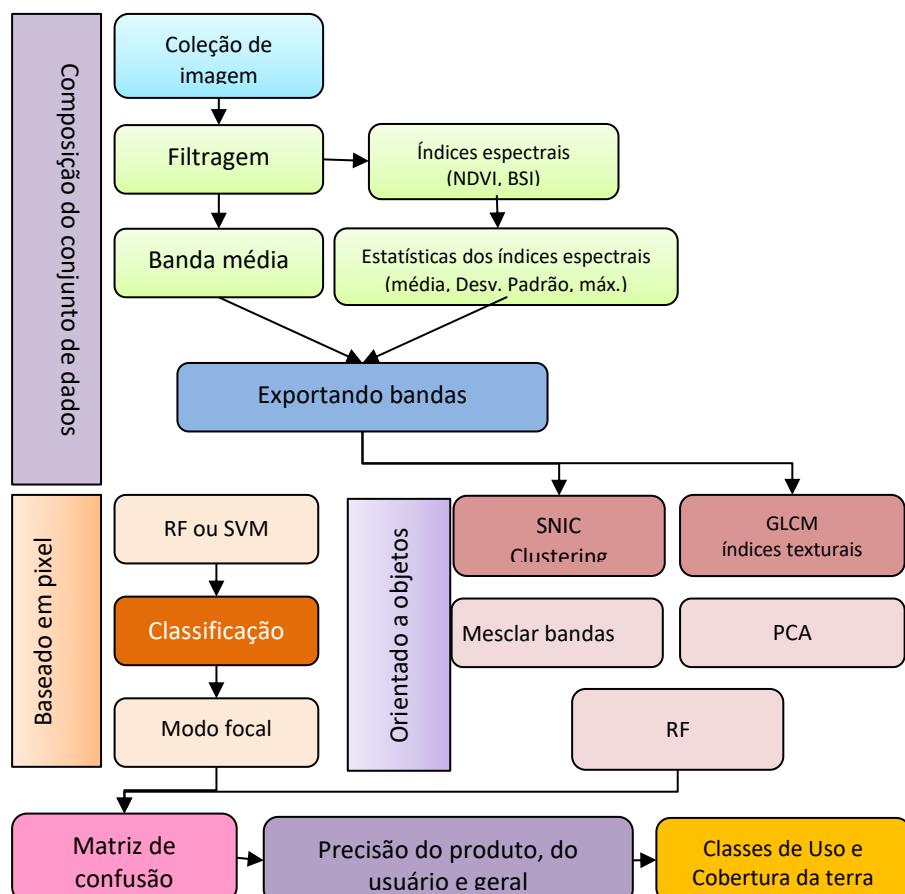
Fonte: Elaborado pelos autores (2025).

Para cada uma dessas classes foram atribuídos pontos de validação, sendo considerados valores variados, de acordo com o tamanho da área estudada. Para obter a classificação da cobertura e uso da terra foram estabelecidas as seguintes quantidades de pontos para cada área: 35 pontos para área urbana, 33 para solo exposto, 65 para vegetação densa, 37 para vegetação aberta e 40 para áreas agrícolas/pastagem e 15 para corpos d'água, totalizando 225 pontos de validação. Vale destacar que a

quantidade de pontos de validação está intrinsecamente relacionada com o tamanho da área de cada classe temática.

Na prática, o processamento dos dados é realizado basicamente em três etapas principais: 1) Composição do conjunto de dados; 2) Baseado em pixel e 3) Avaliação de precisão, conforme mostrado no fluxograma da Figura 4.

Figura 4 - Fluxo de trabalho metodológico implementado no Google Earth Engine (GEE)



Fonte: Adaptado de Tassi e Vizzari (2020)

NDVI: Índice de Vegetação por Diferença Normalizada; **BSI:** Índice de Solo Exposto; **RF:** *Random Forest*; **SVM:** Algoritmo de aprendizado de máquina, baseado em vetores de suporte; **LULC:** Uso e Cobertura da terra; **SNIC:** Algoritmo de segmentação utilizado na análise orientada a objetos; **GLCM:** Matriz de Coocorrência de Níveis de Cinza; **PCA:** Análise de Componentes Principais.

As etapas detalhadas na Figura 4 foram executadas em ambiente GEE, o que permitiu o processamento em nuvem de grandes volumes de dados, otimizando a seleção de imagens apropriadas para análise multitemporal da cobertura terrestre. Tal procedimento segue abordagem metodológica consolidada na literatura, sendo amplamente utilizado em estudos de monitoramento ambiental e mudanças no uso da terra a exemplo de estudo de Gorelick et al. (2017) e Tassi e Vizzari (2020).

Nessa etapa, foram também gerados índices espectrais, como o NDVI, que realça áreas de vegetação, e o BSI, que evidencia superfícies expostas, além do cálculo da banda média e de estatísticas descritivas, como média e desvio padrão, para caracterizar a variabilidade espectral. As bandas resultantes são exportadas e preparadas para a etapa de classificação, que pode seguir duas abordagens distintas: baseada em pixel ou orientada a objetos. Na classificação pixel a pixel, algoritmos supervisionados como *Random Forest* (RF) atribui rótulo de uso e cobertura a cada elemento da imagem, enquanto operações como o modo focal realizam um pós-processamento para suavizar ruídos e eliminar pixels isolados.

A classificação orientada a objetos empregada nesse estudo, foi utilizado pelo modelo classificador *radom forest*, método como o *SNIC Clustering*, que é empregado ao modelo para segmentar a imagem em unidades homogêneas, enquanto índices texturais derivados da Matriz de Coocorrência de Níveis de Cinza (GLCM), essa matriz avalia como os tons de cinza (níveis de pixel) se relacionam espacialmente na imagem. A partir dessa matriz, calculam-se estatísticas de textura, como contraste, homogeneidade, entropia, energia e correlação. Isso é importante, nas aplicações que combinam sensoriamento remoto com *Machine Learning*, pois essa técnica pode resolver problemas em situações em que duas áreas apresentam valores médios de reflectância semelhantes, mas texturas muito diferentes, como por exemplo, uma área agrícola e uma floresta nativa densa.

Já à análise de Componentes Principais (PCA) é aplicada pelo modelo para reduzir a dimensionalidade sem perda significativa de informação, tornando o processamento mais eficiente, antes da aplicação dos algoritmos de classificação RF. Finalmente, a qualidade do resultado é avaliada por meio da matriz de confusão, que permite calcular métricas como precisão do produto, precisão do usuário e precisão geral, assegurando a confiabilidade do mapa final, que representa as classes de uso e cobertura da terra, como área urbana, corpos d'água, vegetação densa e aberta, uso agrícola/pastagem e solo exposto.

O método empregado no estudo para caracterização do uso e cobertura da terra propôs processamento com base em classificação Orientada a Objetos, utilizando o modelo classificador *Random Forest*. De maneira sucinta, este classificador utiliza pontos aleatórios, preestabelecidos pelo analista, os quais o modelo de classificação irá atuar baseado nestes pontos de treino. É válido salientar, que geralmente, é recomendado a utilização de 70% de pontos de treino, e 30% de pontos de validação.

As amostras de validação são usadas para avaliar o desempenho do modelo, aplicando o classificador sobre esses pontos e comparando as classes previstas com as classes reais. Esse processo gera uma matriz de confusão, a partir da qual são extraídas métricas como a acurácia global e o índice

Kappa, permitindo quantificar a confiabilidade da classificação. O script ainda adiciona ao mapa, para inspeção visual, as camadas correspondentes aos pontos de amostra e de validação.

Para mensurar a confiabilidade do modelo, bem como, a acurácia do resultado, foi aplicado o Índice Kappa de Cohen (1960), que é uma métrica estatística utilizada para medir a concordância entre uma classificação automática (como a feita com *Random Forest*) e uma classificação de referência (pontos de validação), representado pela Equação, $K = \frac{P_o - P_e}{1 - P_e}$. Onde, P_o = proporção de concordância observada (acertos reais / total) e P_e = proporção de concordância esperada ao acaso (soma dos produtos marginais das linhas e colunas dividido pelo total ao quadrado).

O índice Kappa mede a concordância entre a classificação e os dados reais, ajustando pelo acaso. Ele varia entre -1 e 1, em que 1 é considerado uma concordância perfeita, 0 é concordância ruim, ou sem concordância, $K > 0,75$ é excelente, 0,40 a 0,75 moderada a boa e $K < 0,40$ fraca.

RESULTADOS E DISCUSSÃO

Análise da Matriz de Confusão e Índice Kappa

A análise da matriz de confusão (Tabela 3) revela um desempenho satisfatório do classificador *Random Forest*, com destaque para classes com separação espectral bem definida. A classe C3 (Vegetação Densa) obteve 100% de acerto (10/10) pontos corretamente classificados), evidenciando que suas características espetrais são nítidas e foram eficientemente reconhecidas pelas variáveis utilizadas bandas espetrais, NDVI (indicador da biomassa verde) e BSI (índice de solo exposto, útil para distinguir superfícies vegetadas de áreas descobertas). A classe C6 (Água) também apresentou desempenho excelente, com 100% de acerto (4/4), confirmando que os corpos hídricos foram bem identificados graças à sua assinatura espectral distinta nas bandas do NIR e SWIR.

Por outro lado, a classe C1 (Área Urbana) mostrou maior confusão: apenas 60% de acerto (3/5), com um ponto classificado como solo exposto (C2) e outro como vegetação aberta (C4). Essa dificuldade decorre da heterogeneidade espectral das áreas urbanas, que frequentemente apresentam respostas semelhantes a solos desnudos e vegetação rala, especialmente em regiões semiáridas. A classe C2 (Solo Exposto) apresentou 75% de acerto (3/4), mas sofreu leve confusão com vegetação densa (C3), possivelmente devido a solos parcialmente cobertos por vegetação esparsa, o que reduz a eficácia isolada do BSI. A classe C5 (Área Agrícola) requer atenção especial: não houve nenhum acerto (0/2), já que todas as amostras foram classificadas como vegetação aberta (C4). Isso indica que, no período analisado, as áreas agrícolas apresentaram assinatura espectral semelhante à vegetação rala ou não foram

adequadamente representadas nas amostras de treinamento. A classe C4 (Vegetação Aberta) teve 100% de acerto (3/3), mas sua pureza foi distorcida ao absorver os pontos incorretos de área agrícola.

A avaliação geral de acurácia, baseada na matriz de confusão, resultou em um índice Kappa de 0,77, indicando boa concordância entre a classificação automática e os dados de referência. Esses resultados confirmam que a combinação de NDVI e BSI auxiliou na diferenciação entre superfícies vegetadas e áreas expostas, embora ajustes adicionais sejam necessários para melhorar a separação entre áreas urbanas, agrícolas e vegetação aberta.

Tabela 3 - Matriz de Confusão da Classificação do Uso e Cobertura da Terra com Base em Algoritmo de Aprendizado de Máquina (*Random Forest*).

Reais	Preditas	C1	C2	C3	C4	C5	C6	Total Reais
C1	Área Urbana	3	1	0	1	0	0	5
C2	Solo Exposto	0	3	1	0	0	0	4
C3	Vegetação Densa	0	0	10	0	0	0	10
C4	Vegetação Aberta	0	0	0	3	0	0	3
C5	Área Agrícola	0	0	0	2	0	0	2
C6	Água	0	0	0	0	0	4	4

Fonte: Elaborado pelos autores (2025).

De acordo com os resultados da matriz de confusão, Tabela 3, indica uma concordância substancial, ou seja, a classificação feita com *Machine Learning (Random Forest)* está muito próxima da realidade observada nos pontos de validação.

A matriz de confusão (Tabela 3) exibe os pontos reais de referência com os pontos classificados pelo modelo. A diagonal principal indica os acertos, enquanto os valores fora da diagonal representam os erros de classificação. O Índice Kappa, calculado a partir dessa mesma comparação, ajustou o nível de concordância observado pelo acaso. Para os dados analisados, a proporção de acertos observados foi de aproximadamente 0.82 e a proporção esperada ao acaso de 0.22, resultando em um Kappa de cerca de 0.77, indicando excelente concordância entre a classificação do modelo e os pontos de referência.

Tabela 4 - Acurácia por classe, mostrando o número de pontos de validação reais, os pontos corretamente classificados, os erros de classificação e a porcentagem de acertos obtida em cada categoria.

Classe (Descrição)	Pontos de Validação (Reais)	Pontos Corretos (Classificação)	Pontos Incorretos (Classificação)	Acurácia (%)
Área Urbana	5	3	2 (1 como C2, 1 como C4)	60%
Solo Exposto	4	3	1 (como C3)	75%
Vegetação Densa	10	10	0	100%
Vegetação Aberta	3	3	0 (mas recebeu 2 pontos de C5)	100%
Área Agrícola	2	0	2 (como C4)	0%
Água	4	4	0	100%

Fonte: Autores (2025)

A análise comparativa mostrada na Tabela 4 entre os pontos de validação e os pontos classificados evidencia como cada etapa do processamento influenciou a qualidade final do mapeamento. O uso das bandas espectrais do Sentinel-2 combinadas com os índices NDVI e BSI no fluxograma permitiu distinguir com alta confiabilidade as classes de Vegetação Densa (C3) e Água (C6), ambas com 100% de acurácia. Esse desempenho está associado à assinatura espectral bem definida desses alvos: a vegetação densa apresenta alto NDVI, enquanto os corpos hídricos possuem baixa refletância no NIR e SWIR, evitando confusão com outras classes.

Por outro lado, as áreas urbanas (C1) e agrícolas (C5) apresentaram menor desempenho devido à sobreposição espectral com solos expostos e vegetação aberta, especialmente em ambientes semiáridos, onde superfícies pavimentadas, telhados claros e solo descoberto podem gerar valores semelhantes de NDVI e BSI. A confusão da classe agrícola (0% de acerto) decorre também da escassez ou da pouca representatividade das amostras de treinamento no conjunto de dados, reforçando a importância da etapa de amostragem no fluxograma. O *Random Forest*, embora robusto, depende diretamente da qualidade e diversidade das amostras para separar classes com assinaturas espectrais próximas.


O índice Kappa obtido ($\kappa = 0,7701$) representa um nível de concordância substancial entre os dados classificados pelo algoritmo de *Machine Learning*, neste caso, o *Random Forest*, e os dados de validação coletados em campo ou previamente definidos como verdade de referência. Nesse sentido, o valor de Kappa obtido demonstra que o modelo de classificação apresenta um desempenho robusto, evidenciando que a maioria das classes de uso e cobertura da terra foram corretamente identificadas com elevada precisão.

Classificação do Uso e Cobertura da Terra

Os resultados da classificação do uso e ocupação no solo dos municípios de Alto do Rodrigues, Jucurutu e Porto do Mangue estão detalhados a seguir.

A classificação do uso e cobertura da terra, mostrado na Figura 5, evidencia que a classe com maior evidência são as áreas de vegetação aberta, (destacada na cor marrom) e áreas com vegetação densa. As áreas de uso agrícola chamam a atenção no município de Alto do Rodrigues, podendo ser visualizado na cor verde claro. Um detalhe para as áreas ocupadas com agricultura compreende grande extensão territorial no município de Alto do Rodrigues, com destaque para as regiões que compreende as margens do rio Pinhas, onde pode ser notado em toda sua extensão atividades agrícolas.

Figura 5 - Classificação do uso e cobertura da terra no município de Alto do Rodrigues-RN, dados de 2021.




Fonte: Elaborado pelos autores (2025)

De acordo com informações estabelecidas no mapa da Figura 5, é claramente notável que as áreas de culturas temporárias (destacadas na cor verde claro), apresentam grande proporção no território do município de Alto do Rodrigues. No referido município, nota-se a presença da agricultura no método, conhecido como Pivô Central. Esse modelo no geral é utilizado por agroindústrias, por se tratar de um método que demanda um custo alto.

Conforme pode ser observado na Figura 6, o município de Jucurutu, destaca-se com maior abrangência territorial, a vegetação aberta, representado na cor marrom, seguido de áreas da vegetação densa, representado na cor verde escuro.

Figura 6 - Classificação do uso e cobertura da terra no município de Jucurutu-RN, dados de 2021.




Fonte: Elaborado pelos autores (2025)

Vale ressaltar, que o município de Jucurutu não é caracterizado por ser um município de grandes extensões territoriais composto de agricultura, mesmo esse município está localizado em uma das maiores microrregiões produtoras do estado do Rio Grande do Norte-RN. Isso deve ser devido ao fato de que Jucurutu não está situado na região que foi contemplada pelo Programa de Apoio e Desenvolvimento da Fruticultura irrigada do Nordeste, instituída em 1996, que teve como objetivo fortalecer a atividade agrícola da região Nordeste do Brasil.

Já o município de Porto do Mangue é um forte produtor de frutas e se destaca também pela extração de sal e criação de camarão em poços artesianos, como demonstrado na Figura 7, na cor azul.

Devido aos poços artesianos, o município de Porto do Mangue apresenta uma significativa área de corpos d'água, quando comparado aos outros municípios da microrregião do Vale do Açu. Paralelamente, observa-se grande extensão territorial de áreas agrícolas, destacado em cor verde claro, situado principalmente na porção oeste do município. Pode ser observado ainda, uma grande faixa de área com solo exposto, devido aos bancos de areia, por decorrência das dunas na parte leste do município próximo a costa oceânica.

Figura 7- Classificação do uso e cobertura da terra no município de Porto do Mangue-RN, dados de 2021.

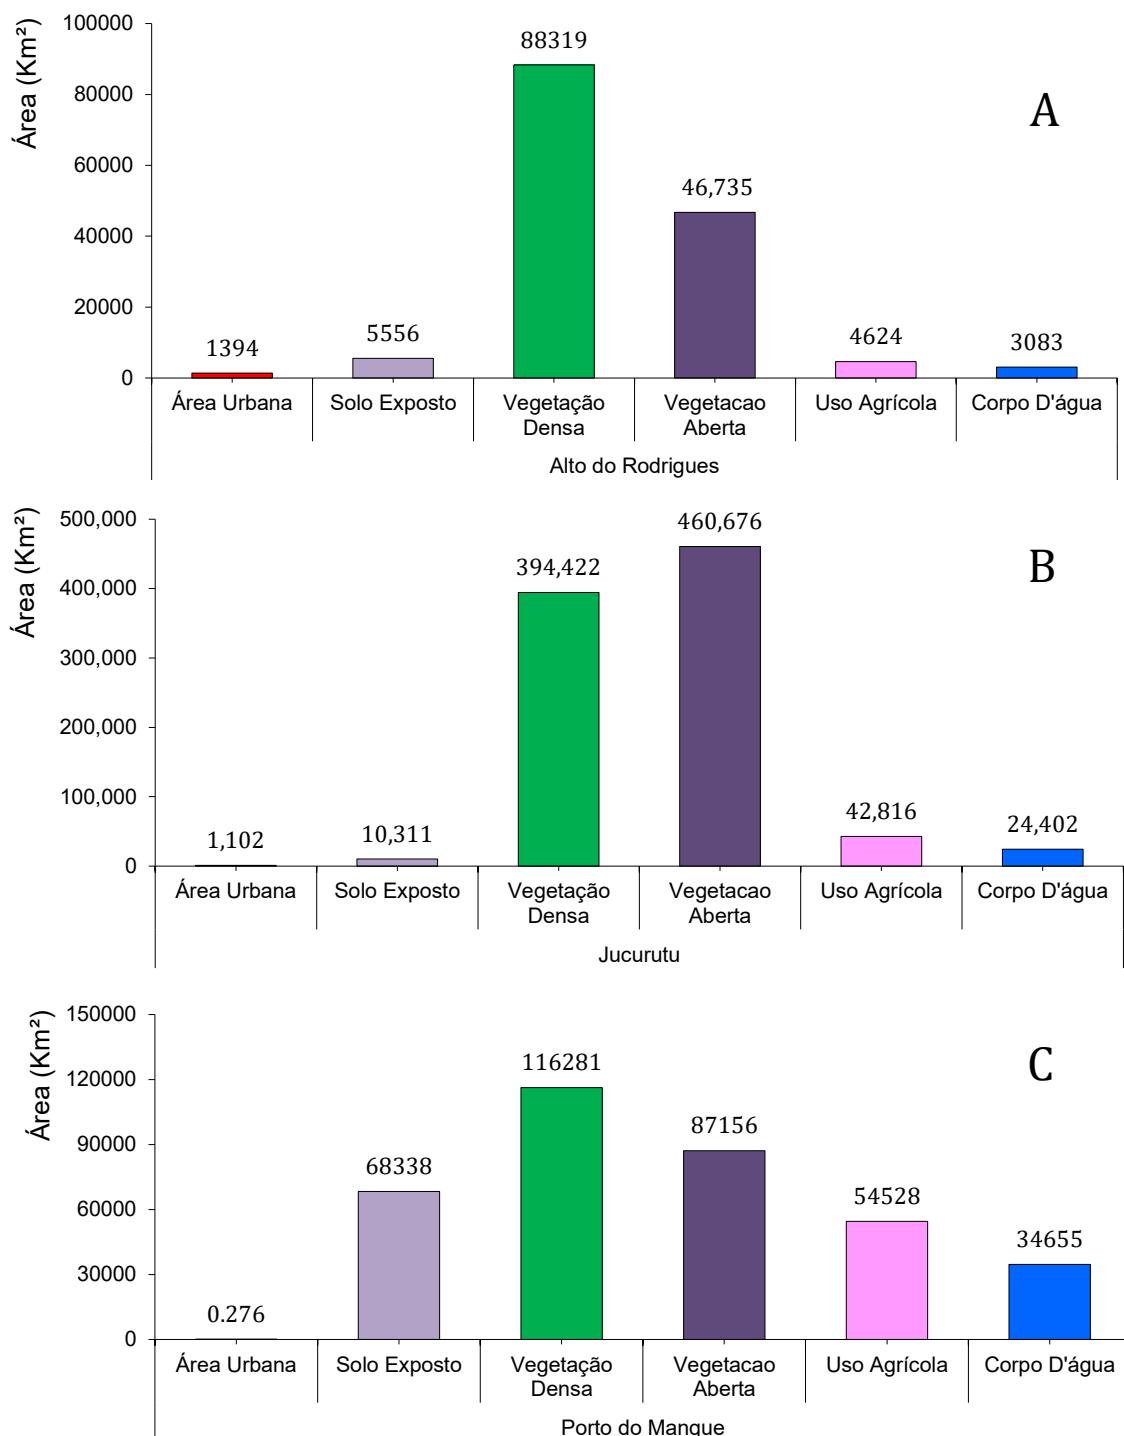


Fonte: Elaborado pelos autores (2025)

Em relação a quantificação das áreas mapeadas e classificadas, de acordo com as classes temáticas preestabelecidas. A classificação também trouxe números que demonstram os somatórios das áreas classificadas por tipo de alvo. Na Figura 8, está exposto o somatório em relação a classificação do uso e cobertura da terra para as 6 classes temáticas utilizadas, área urbana (cor vermelho), solo exposto

(cor amarelo), vegetação densa (cor verde escuro), vegetação aberta (cor marrom), uso agrícola/pastagem (cor verde claro) e corpos d'água (cor azul).

Figura 8-Somatório das áreas classificadas por cidade: Alto do Rodrigues (A), Jucurutu (B), Porto do Mangue (C).



Fonte: Elaborado pelos autores (2025).

As áreas classificadas com maiores extensões no município de Alto do Rodrigues (Figura 8-A), compreende a vegetação densa, com 88.319 km², correspondendo 46,15 % do território total do município Alto do Rodrigues-RN, que tem 191.334 km² de extensão territorial. As áreas de solo exposto, de acordo com a classificação, somam 5.556 Km² (2,9 %) da extensão territorial. As áreas com vegetação aberta, compreendem, 46.735 Km², (24,42%) em relação a área total do município. As classes temáticas área urbana (1,394 Km²), uso agrícola (4.624 Km²) e corpos d'água (3.083 Km²). A área urbana, uso agrícola e corpos d'água somam juntas 2,41% do território total do município Alto do Rodrigues.

Foi observado que Porto do Mangue (Figura 8-B) é o município que tem maior abrangência territorial em termos de áreas agrícolas, somando 54.528 km². Em relação a Alto do Rodrigues, que foi o município que apresentou menor áreas com atividade agrícola (4.624 km²), enquanto o município de Porto do Mangue tem uma área com bem superior, somando uma diferença, quando comparado a Alto do Rodrigues, de 49.904 km². Porto do Mangue se destaca ainda no tocante aos corpos d'água, pois são áreas de criação de camarão e produção de sal. A área de corpos de água soma 34.655 km², o que representa 9,37 %, da área total do município.

As cidades de Alto do Rodrigues (Figuras 8-A) e Jucurutu (Figuras 8-B) são os dois municípios dentre os três mencionados, que apresentam menor cobertura da terra para uso agrícola. Já a cidade de Porto do Mangue são os dois municípios com maior atividade agrícola. A área urbana é bastante reduzida em todos os municípios analisados, com destaque para Porto do Mangue, cujo valor é inferior a 1 km² (0.276 km²). Já Alto do Rodrigues apresenta a maior área urbana entre os três municípios, com 1.394 km², indicando maior urbanização relativa.

No que se refere ao solo exposto, Porto do Mangue apresenta a maior área (68.388 km²), sugerindo a existência de áreas degradadas ou sem cobertura vegetal significativa, o que pode estar associado a riscos ambientais como erosão. A vegetação densa é predominante em todos os municípios, com destaque para Jucurutu (394.422 km²), evidenciando a presença de áreas com vegetação mais preservada ou biomas mais fechados. Alto do Rodrigues, apesar de apresentar a menor área relativa de vegetação densa (88.319 km²), ainda mantém uma cobertura considerável.

Tabela 5-Áreas (km²) das classes de cobertura e uso do solo nos municípios de Alto do Rodrigues (Figura 8-A), Jucurutu (Figura 8-B) e Porto do Mangue (Figura 8-C), obtidas a partir da classificação temática. Os valores indicam a extensão territorial ocupada por cada classe em cada município.

Classe	Alto do Rodrigues (Fig. 8-A) [km ²]	Jucurutu (Fig. 8-B) [km ²]	Porto do Mangue (Fig. 8-C) [km ²]
Área Urbana	1394	1102	0,276
Solo Exposto	5556	10311	68338
Vegetação Densa	88319	394422	115281
Vegetação Aberta	46735	460676	87155
Uso Agrícola	4624	42815	54528
Corpos d'Água	3083	24402	34655

Fonte: Elaborado pelos autores (2025)

A vegetação aberta também representa uma porção significativa da cobertura da terra. Em Jucurutu, essa categoria atinge um valor expressivo de 460.676 km². Esse tipo de vegetação pode representar pastagens naturais, áreas de transição ou desmatamentos recentes. A grande extensão de vegetação aberta em Jucurutu pode estar associada a práticas de uso rural extensivo.

No que diz respeito ao uso agrícola, Alto do Rodrigues apresenta a menor área destinada à agricultura (4.624 km²), o que pode refletir menor dependência econômica dessa atividade ou limitações relacionadas ao solo e ao clima. Por fim, em relação aos corpos d'água, Porto do Mangue se destaca com a maior extensão (34.655 km²), o que é coerente com sua localização litorânea e possível presença de lagoas, estuários ou manguezais.

CONCLUSÃO

Foi possível observar por meio do método empregado na pesquisa, que todos os municípios analisados predominam a vegetação densa e a vegetação aberta. No entanto, os municípios de Porto do Mangue apresentam áreas com extensão de ocupação agrícola significativas e importante polos de produção de alimento da microrregião do Vale do Açu-RN.

Devido ao desenvolvimento socioeconômico e ao rápido crescimento populacional. O estudo mostrou que a intensificação das atividades humanas nos municípios monitorados, devido a expansão das atividades agrícolas.

Em termos de uso e cobertura da terra, pode-se constatar nos resultados que o solo das cidades estudadas é constituído em grande parte por terras coberta por vegetação nativa, com pequenas áreas agrícolas, com exceção da cidade de Porto do Mangue. As áreas utilizadas para atividades agrícolas são áreas destinadas à atividade e exploração da agricultura familiar, pecuária, em pequenas áreas para silvicultura e outras atividades agrícolas de menor porte. Mas em grande parte das áreas ocupadas com agricultura, essas são oriundas das agroindústrias.

A predominância das áreas vegetadas nos três municípios estudados. Jucurutu apresentou a maior área de vegetação densa (394.422 km²) e vegetação aberta (460.676 km²), enquanto Alto do Rodrigues registrou a menor área agrícola (4.624 km²) e Porto do Mangue destacou-se pela maior extensão destinada à agricultura (54.528 km²) e corpos d'água (34.655 km²). As áreas urbanas foram reduzidas em todos os municípios, com Porto do Mangue apresentando valor inferior a 1 km² (0,276 km²). O solo exposto foi mais expressivo em Porto do Mangue (68.338 km²), sugerindo maior pressão antrópica, enquanto Alto do Rodrigues manteve a menor proporção relativa de vegetação densa (88.319 km²), ainda assim representando cobertura significativa do território.

O valor do índice Kappa (0,77) reforça a qualidade geral da classificação, indicando uma boa concordância entre os dados classificados e os dados reais, além do mero acaso. No entanto, ajustes são recomendados, principalmente no que se refere à discriminação entre vegetação aberta e áreas agrícolas. O aprimoramento do conjunto de treinamento, a inclusão de novas bandas e índices, ou a utilização de imagens multitemporais podem contribuir para melhorar o desempenho das classes mais confusas.

Assim, os erros observados indicam a necessidade de ajustar o processo, seja pela inclusão de variáveis adicionais (como índices sazonais ou de textura), seja pelo refinamento do conjunto de treinamento, para melhorar a discriminação entre áreas urbanas, agrícolas e vegetação aberta.

Portanto, apesar de algumas limitações pontuais, os resultados da classificação indicam que a abordagem metodológica adotada, envolvendo imagens do Sentinel-2, o NDVI e o algoritmo *Random Forest* se mostrou eficaz para o mapeamento do uso e cobertura da terra na microrregião do Vale do Açu. A acurácia substancial comprovada pelo índice Kappa atesta a confiabilidade dos dados classificados, tornando-os apropriados para aplicações em planejamento territorial, monitoramento ambiental e formulação de políticas públicas voltadas à conservação do bioma Caatinga.

Por fim, percebe-se que a mudança na estrutura física da terra em termos de vegetação, uso e cobertura da terra no bioma Caatinga, esteja associado às atividades humanas de diversas formas, tanto pela agricultura familiar, como a agricultura de alta produtividade.

REFERÊNCIAS

- ALVES, Jose Jakson Amancio; DE ARAÚJO, Maria Aparecida; DO NASCIMENTO, Sebastiana Santos. Degradação da Caatinga: uma investigação ecogeográfica. **Revista Caatinga**, v. 22, n. 3, p. 126-135, 2009. Disponível em: <https://periodicos.ufersa.edu.br/caatinga/article/view/560/645>. Acesso em jan. de 2025.
- CAMPOS, S. A. C.; FERREIRA, M. D. P.; COELHO, A. B.; LIMA, J. E. de. Degradação ambiental agropecuária no bioma caatinga. **Revista Economia do Nordeste**, v. 46, n. 3, p. 155-170, jul./set. 2015. Disponível em: <https://doi.org/10.61673/ren.2015.265>. Acesso em: 25 nov. 2024.
- COHEN, Jacob. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. 20, n. 1, p. 37–46, 1960. Disponível em: DOI: 10.1177/001316446002000104. Acesso em 9 mar. 2025.
- EMBRAPA TERRITORIAL. **Sistema de Inteligência Territorial Estratégica do Bioma Caatinga**. Campinas, 2022. Disponível em: <https://www.embrapa.br/bioma-caatinga>. Acesso em: 30 de abr. de 2023.
- FLORENZANO, T. G. Geomorfologia: Conceitos e tecnologias atuais. **São Paulo: Oficina de Textos**, 2008.
- GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 2017. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0034425717302900>. Acesso em: 12 fev. de 2025.
- INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA-IBGE. Brasil. Rio de Janeiro, 2022. Disponível em: <https://cidades.ibge.gov.br/brasil/rn/parau/panorama>. Acesso em: 28 de abr. de 2023.
- INSTITUTO NACIONAL DO SEMIÁRIDO – INSA. O Semi-Árido Brasileiro. **Portal Gov.br, Ministério da Ciência, Tecnologia e Inovações**. 2020. Disponível em: <https://www.gov.br/insa/pt-br/semiarido-brasileiro>. Acesso em: 30 de abr. de 2023.
- KUMAR, Lalit; MUTANGA, Onisimo. Google Earth Engine applications since inception: Usage, trends, and potential. **Remote Sensing**, v. 10, n. 10, p. 1509, 2018. Disponível em: <https://doi.org/10.3390/rs11050591>. Acesso em: 30 de abr. de 2023.
- LAMBIN, Eric F.; GEIST, Helmut J.; LEPERS, Erika. Dinâmica das Mudanças no Uso e Cobertura da terra em Regiões Tropicais, **Revisão Anual do Meio Ambiente e Recursos**, 2003 28:1, 205-241. Disponível em: <https://www.annualreviews.org/doi/full/10.1146/annurev.energy.28.050302.105459>. Acesso em: 25 de abr. de 2023.
- MAPA, MINISTÉRIO DA AGRICULTURA PECUÁRIA E DO ABASTECIMENTO. **Secretaria Executiva**. Programa de apoio e desenvolvimento da fruticultura irrigada do Nordeste. Ministério da Agricultura e do Abastecimento, 1998.