



RAFAELA NARDY DELGADO

**CLASSIFICAÇÃO E DINÂMICA DA COBERTURA DO SOLO
UTILIZANDO O *GOOGLE EARTH ENGINE***

**LAVRAS – MG
2022**

RAFAELA NARDY DELGADO

**CLASSIFICAÇÃO E DINÂMICA DA COBERTURA DO SOLO UTILIZANDO O
*GOOGLE EARTH ENGINE***

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para obtenção do título de Bacharel.

Prof. Dr. Fausto Weimar Acerbi Júnior
Orientador
Me. Gustavo Antomar Batista Gontijo
Coorientador

**LAVRAS – MG
2022**

RAFAELA NARDY DELGADO

**CLASSIFICAÇÃO E DINÂMICA DA COBERTURA DO SOLO UTILIZANDO O
*GOOGLE EARTH ENGINE***

Monografia apresentada à Universidade Federal de Lavras, como parte das exigências do Curso de Engenharia Florestal, para obtenção do título de Bacharel.

APROVADA em 8 de setembro de 2022.

- | | |
|--|-----------|
| 1. Prof. Dr. Fausto Weimar Acerbi Júnior | DCF/UFLA. |
| 2. Me. Gustavo Antomar Batista Gontijo | DCF/UFLA |
| 3. Dr. Mônica Canaan Carvalho | DCF/UFLA. |

Prof. Dr. Fausto Weimar Acerbi Júnior
Orientador
Me. Gustavo Antomar Batista Gontijo
Coorientador

**LAVRAS-MG
2022**

RESUMO

O desmatamento que vem ocorrendo na região amazônica, incentivado pela expansão de atividades agropecuárias devido ao avanço do arco do desmatamento, é uma grave ameaça a conservação dos recursos naturais pelos distúrbios que causam na conservação dos mesmos. Dentre os municípios do estado Amazonas incluídos no arco do desmatamento, encontra-se o município de Lábrea que vem liderando com a contribuição para o aumento do desmatamento. Neste sentido, este trabalho tem como objetivo analisar a precisão da classificação da cobertura do solo para o município de Lábrea para anos de 2020 e 2021, assim como a precisão dessa classificação, por meio do processamento de imagens utilizando a plataforma do *Google Earth Engine* (GEE). Para a realização deste trabalho, foi usada a linguagem de programação em *JavaScript* no GEE, para o Índice de Vegetação por Diferença Normalizada (NDVI) e para a classificação das imagens. Foram utilizadas imagens do satélite Landsat-8 OLI/TIRS e imagens Sentinel 2. Os resultados encontrados mostraram uma significativa alteração na cobertura vegetal entre esses dois anos, assim como uma precisão excelente de classificação. Destaca-se a importância do GEE, do NDVI e da classificação da cobertura do solo para o monitoramento e controle ambiental visto que através dos resultados obtidos foi possível identificar alterações na cobertura vegetal que vem ocorrendo nessa região ao longo dos anos.

Palavras-chave: Sensoriamento Remoto. *Random Forest*. Mapeamento.

LISTA DE FIGURAS

Figura 1- Área, em km ² , do incremento de desmatamento anual do município de Lábrea desde o ano de 2008 até o ano de 2021.	10
Figura 2 - Exemplificação de como são definidas as árvores de decisão do algoritmo <i>Random forest</i>	13
Figura 3 - Fluxograma com a sequência de processamento das etapas da metodologia desenvolvida.	16
Figura 4 - Mapa de localização da área de estudo, município de Lábrea, pertencente ao estado do Amazonas.	17
Figura 5 - Layout do Code Editor do Google Earth Engine onde se elabora os scripts e visualiza-se os produtos obtidos.	19
Figura 6 - Trecho do script onde se define a área de estudo, a coleção das imagens Landsat 8 e aplicação da máscara de nuvens. (continua).....	20
Figura 7 - Trecho do script onde se define a área de estudo, a coleção das imagens Sentinel-2 e aplicação da máscara de nuvens.	22
Figura 8 - Definição e características das classes que serão usadas na classificação da cobertura do solo nas imagens Landsat 8 2020 e 2021.	23
Figura 9 - Trecho do script de classificação da cobertura do solo utilizando as 5 classes definidas para mapeamento das imagens Landsat 8, tanto para 2020 quanto para 2021.	24
Figura 10 - Trecho do script em que se aplica os hiperparâmetros para calibração do número de árvores a serem executados pelo algoritmo Random forest.	26
Figura 11 - Resultado da calibração do número de árvores a serem executados pelo algoritmo Random forest de acordo com a função do hiperparâmetro de Tuning, para uma classificação de cobertura do solo com melhor precisão, para o ano de 2020.	27
Figura 12 - Resultado da calibração do número de árvores a serem executados pelo algoritmo Random forest de acordo com a função do hiperparâmetro de Tuning, para uma classificação de cobertura do solo com melhor precisão, para o ano de 2021.	28
Figura 13 - Trecho do script em que se obtém os índices de vegetação através da imagem Landsat 8, para análise da dinâmica e classificação da cobertura do solo, para ambos os anos: 2020 e 2021.	29

Figura 14 - Imagens de satélite Sentinel-2 para a área de estudo, município de Lábrea, para os anos 2020 e 2021 nas composições de cor verdadeira e falsa cor.	32
Figura 15 - Imagens de satélite Landsat 8 dos anos 2020 e 2021, para o município de Lábrea, área de estudo, nas composições de cor verdadeira e falsa cor.	33
Figura 16 - Resultado do mapeamento da classificação de cobertura do solo para a área de estudo, município de Lábrea, para os anos de 2020 e 2021.	34
Figura 17 - Índice de vegetação NDVI, para anos 2020 e 2021, do município da área de estudo, Lábrea.....	36
Figura 18 - Índice de vegetação NDVI diferença, entre os anos de 2021 e 2020, para o município de Lábrea, área de estudo.	37

LISTA DE TABELAS

Tabela 1 - Interpretação da qualidade da classificação de cobertura do solo de acordo com os valores do Índice Kappa.....	16
Tabela 2 - Resultado das áreas em km ² das classes mapeadas da cobertura do solo para o ano de 2020 e 2021 para o município de Lábrea.....	35
Tabela 3 - Resultados da matriz confusão gerados do mapeamento da classificação de cobertura do solo para o ano de 2020 do município de Lábrea.....	38
Tabela 4 – Matriz confusão da classificação de cobertura do solo para o ano de 2021 do município de Lábrea.	38
Tabela 5 - Resultados obtidos para as acurácias do produtor e do usuário (em porcentagem) para as 5 classes mapeadas, para os anos de 2020 e 2021.	39

SUMÁRIO

1	INTRODUÇÃO	7
2	REFERENCIAL TEÓRICO	8
2.1	Histórico desmatamento em Lábrea	9
2.2	Google Earth Engine	11
2.3	Random Forest	12
2.4	Medidas de acurácia	13
3	MATERIAIS E MÉTODOS	16
3.1	Área de estudo	16
3.2	Obtenção e pré-processamento das imagens	18
3.3	Classificador <i>Random forest</i> e sua parametrização	23
3.4	Análise da dinâmica da cobertura do solo	28
3.5	Avaliação da classificação	31
4	RESULTADOS E DISCUSSÕES	31
5	CONSIDERAÇÕES FINAIS	40
	REFERÊNCIAS BIBLIOGRÁFICAS	42

1 INTRODUÇÃO

As transformações que ocorrem na cobertura do solo, principalmente, as promovidas por ações antrópicas, possuem grandes impactos nos ecossistemas que ainda não são plenamente conhecidos (STEFFEN et al., 2004). A detecção dessas mudanças pode ser definida como as alterações ocorridas através do tempo sobre a superfície terrestre de onde pode se realizar comparações entre imagens obtidas em diferentes momentos (SIMEÃO DE MEDEIROS, 1987).

A Amazônia vem sofrendo intensa interferência humana na cobertura do solo, causando inúmeras mudanças nos processos que controlam a sustentabilidade de seus ecossistemas (FEARNSIDE, 1996). Tais modificações são resultantes de vários fatores, como por exemplo: questões macroeconômicas envolvendo exploração de madeira, pecuária (MERTENS et al., 2002), cultivos agrícolas e aberturas de estradas (NEPSTAD et al., 2000). Devido a esses fatores, a região se tornou uma nova fronteira de exploração, tendo áreas extensas e baratas, e ainda contou desde a década de 40, com incentivos fiscais sob forma de políticas públicas para ocupação da região, o que desencadeou um forte movimento migratório (HECHT, 1985); BECKER, 1998; CASTRO, 2005).

A região vem sofrendo, desde então, com o desmatamento incentivado pela expansão das atividades agropecuárias, e devido ao avanço do chamado arco do desmatamento em direção a Amazônia (LAURANCE, 2000; SAWYER, 2001). Segundo Lean et al. (1996), o desmatamento é uma grave ameaça para a conservação dos recursos naturais, devido aos distúrbios que provoca nos estágios de regeneração natural e nas perdas das funções na ciclagem de nutrientes e água. Nepstad et al. (2006) alertam que a pressão sob essa região irá continuar considerando o avanço da globalização dos mercados de soja e carne. Sendo assim, torna-se extremamente importante para ações de conservação e preservação a análise da dinâmica da cobertura vegetal. Dentro desse contexto, as geotecnologias, em especial o Sensoriamento Remoto (SR) em conjunto com o Sistema de Informações Geográficas (SIG), ganham grande destaque como ferramentas essenciais no auxílio à pesquisa em diversas áreas (COELHO, 2010; FITZ, 2008; LO; YEUNG, 2003).

As geotecnologias são definidas como um grupo de aparatos tecnológicos que unem análises de dados, processamento e coleta, sendo que os mesmos são capazes de investigar a

dinâmica de cobertura terrestre a nível local, regional ou municipal (GOLLNOW; LAKES, 2014). Desta forma, um mapeamento adequado colabora com o controle e o planejamento da gestão sustentável dos recursos naturais (ALMEIDA; VIEIRA, 2014).

Para realização desses mapeamentos há necessidade do conhecimento de tecnologias espaciais modernas, as geotecnologias (VALE, 2019). Uma geotecnologia que funciona como uma plataforma online que contém uma série de dados ambientais globais, capaz de auxiliar no desenvolvimento de pesquisas e análises da cobertura do solo é o Google Earth Engine (GEE). Gorelick et al. (2017) caracteriza essa plataforma em um catálogo de dados multi-petabyte de imagens orbitais combinado a um serviço de processamento computacional em nuvem, de alto desempenho. É acessada e controlado por uma API (Application Programming Interface) e associada a um IDE (Interactive Development Environment) que permite o processamento e a visualização rápida dos resultados alcançados.

O seu principal objetivo é analisar dados ambientais, para isso ela fornece ferramentas e uma vasta capacidade computacional de realizações de análises e exploração de uma vasta amplitude de dados, auxiliando assim em detecção de desmatamentos, classificação de cobertura do solo e suas alterações, assim como estimativas de biomassa florestal e de carbono (GORELICK et al., 2017).

Assim, é esperado que as ferramentas disponibilizadas pelo Google Earth Engine permitam auxiliar no mapeamento rápido e com precisão de cobertura solo. Nesse sentido, o objetivo deste trabalho foi avaliar a precisão da classificação de cobertura do solo do município de Lábrea, no estado do Amazonas, para os anos de 2020 e 2021, realizada utilizando a plataforma Google Earth Engine, bem como detectar as alterações ocorridas nas áreas das classes mapeadas.

2 REFERENCIAL TEÓRICO

Esse levantamento teve como propósito reunir trabalhos realizados no estado do Amazonas com o uso de geotecnologias e sobre os processos de classificação da cobertura do solo, assim como pesquisas realizadas utilizando o GEE. Realizada por meio de pesquisa bibliográfica nacional e internacional com o objetivo de conhecer e desenvolver a temática desse estudo.

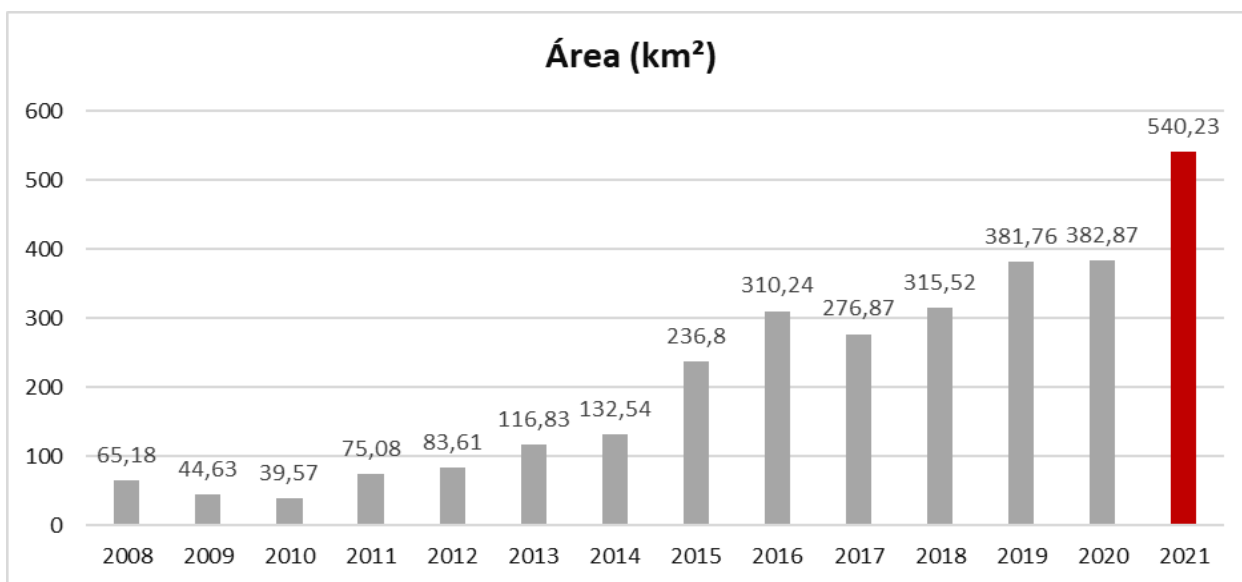
2.1 Histórico desmatamento em Lábrea

A busca por terras agrícolas, ocorrem com grande frequência na região Amazônica, por conter inúmeros recursos naturais, o que provocou um avanço significativo em sua exploração (FERREIRA; VENTICINQUE; ALMEIDA, 2005). Com o passar dos anos, foi se alastrando os desmatamentos nessa região, originando consequências econômicas, naturais e sociais (CARVALHO; MAGALHÃES; DOMINGUES, 2016; FEARNSSIDE; GRAÇA, 2006).

Dentre as regiões mais recentes de exploração, se localiza Lábrea, que faz parte da expansão da fronteira da agropecuária (MEDEIROS, 2019). Segundo Ferrarini (1980), desde o início Lábrea era caracterizado pelo extrativismo, inicialmente pela borracha e ao longo do tempo por outros produtos como a castanha, a sorva, óleos de copaíba e andiroba e a madeira. Sua estruturação se deu com base na economia da borracha. Segundo Ferrarini (1980), desde sua fase áurea da borracha, onde houve grande imigração de nordestinos, estando estritamente ligada ao primeiro ciclo da borracha, onde ocorria grande concentrações de árvores seringas no entorno do rio Purus e afluentes. Com o declínio dessa economia, a produção agrícola ganhou espaço (MEDEIROS, 2019).

Segundo dados do Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite - PRODES (2022), projeto que realiza o monitoramento por satélite do desmatamento por corte raso na Amazônia Legal, desde o ano de 2008 até o ano de 2021, o município apresenta um incremento de desmatamento acumulado de 3.001,72km², sendo que entre os anos de 2020 e 2021 houve o registro do intervalo com maior incremento de desmatamento, 540,23 km² (Figura 1), sendo o município do estado do Amazonas que apresentou maior área desmatada.

Figura 1- Área, em km², do incremento de desmatamento anual do município de Lábrea desde o ano de 2008 até o ano de 2021.



Fonte: PRODES (2022), do autor (2022).

Em 2008, de acordo com a Portaria n° 28/2008, Decreto n° 6.321 de 21 de dezembro de 2007, no âmbito do Ministério de Meio Ambiente (MMA), o município de Lábrea estava então inserido na região do Arco do Desmatamento, passando a integrar a Lista de municípios prioritários para ações que visam a prevenção e controle do desmatamento, onde seriam priorizadas medidas de integração e aperfeiçoamento das ações de monitoramento e controle dos órgãos federais, incentivo de atividades econômicas e ambientalmente sustentáveis e ordenamento fundiário e territorial.

Por sua grande extensão territorial e ao fato dos desmatamentos ocorrerem de forma isolada e organizada, pelo fato de grande parte das áreas da região serem fazendas de pecuária, que não são alinhadas com a economia e administração municipal, o município não consegue atender as demandas de fiscalização e ordenamento fundiário, atividades que se tornam de grande importância nos últimos anos (CENAMO; CARRERO; SOARES, 2011).

Como existe a possibilidade de regularização de terras ocupadas ilegalmente, o que contribui e torna atrativo o desmatamento nessas regiões de fronteira, se espera que a legislação resolva essas questões (FEARNSIDE; GRAÇA, 2006).

2.2 Google Earth Engine

As geotecnologias são tecnologias espaciais modernas que permitem a detecção e avaliação de mudanças no espaço territorial (VALE, 2019). Uma ferramenta que vem trazendo otimização de tempo e custo, o que auxilia o desenvolvimento de estudos e pesquisas é o *Google Earth Engine* (GEE). O GEE está conectado ao Google Drive, plataforma gratuita, que oferece espaço limitado, 15 GB, para armazenamento. Essa integração, entre GEE e Google drive, permite a importação e exportação de arquivos produzidos na plataforma do GEE, sendo necessário apenas internet para obtê-los, sem a necessidade de um espaço físico para armazenamento de dados (BALBINOT et al., 2016). Foi desenvolvida para análises espaciais em escala planetária, com a disponibilidade de imagens globais de satélites, atualizadas diariamente (GORELICK et al., 2017).

Segundo Taurion (2009), essa plataforma pode ser classificada como um modelo de PaaS (*Platform as a Service*), que propõe criar um desenvolvimento de aplicações para computação em nuvem. Esse modelo fornece um conjunto de ferramentas para que o usuário possa desenvolver, implantar e administrar o *software*.

O processamento em nuvem do GEE permite a integração de um conjunto de dados geoespaciais com cobertura global, com capacidade de armazenamento e processamento altamente elevados, além de ser um ambiente integrado de desenvolvimento que suporta a implementação de algoritmos de análise e processamento de dados nas linguagens de *JavaScript* e *Python* (GORELICK et al., 2017). Além de conter dados já disponíveis em sua infraestrutura, o usuário pode enviar seus próprios dados produzidos para integrar o banco de dados da nuvem (GANEM, 2017). Apresenta também a vantagem de permitir ao usuário realizar desde análises estatísticas simples até operações complexas, como geoestatística e extração de informações das imagens (GORELICK et al., 2017).

Apesar de ser recente o GEE vem sendo utilizado em várias pesquisas científicas, incluindo tópicos como mudança de cobertura florestal em escala global (HANSEN et al., 2018), índices de vegetação (AIRES, 2018; HUANG et al., 2017; KELLEY; EVANS; POTTS, 2017), mapeamento da expansão urbana (ZHANG et al., 2015), estimativa de produção agrícola (LOBELL et al., 2015), mapeamento do risco de áreas susceptíveis a enchente (COLTIN et al., 2016), dinâmica de água doce superficial disponível no mundo (PEKEL et al., 2016). Além de ser usado como uma

importante ferramenta de um projeto brasileiro, que é o Projeto de Mapeamento Anual da Cobertura e Uso do solo no Brasil (MapBiomias).

2.3 Random Forest

O *Random forest* é um algoritmo de *machine learning* que utiliza um conjunto de árvores de decisão para realização das classificações e estimativas por meio de regressão (MAXWELL; WARNER; FANG, 2018). É um método de classificação supervisionado não paramétrico que faz previsões a partir de múltiplas árvores de decisão, onde cada uma delas é gerada a partir dos valores de um vetor aleatório (BREIMAN, 2001).

De acordo com Neto (2014), o *Random forest* tem como finalidade originar várias árvores de decisão por meio de grupos de atributos escolhidos aleatoriamente em relação ao grupo original. Ainda segundo esse autor, estes atributos finais são definidos como uma amostragem onde há reposição melhorando a interpretação dos dados. Com a quebra desses dados e a formação de novos subgrupos é que ocorre a formação da árvore de decisão (LORENZETT; TELÖCKEN, 2016).

O classificador *Random forest* é uma combinação de preditores das árvores, ou seja, cada árvore depende dos valores de um vetor aleatório da amostra de forma independente e com a mesma distribuição para todas as árvores da floresta (BREIMAN, 2001). A criação das árvores se dá desenhando um subconjunto de amostras de treinamento através da substituição. Isso significa que a mesma amostra pode ser selecionada várias vezes, enquanto outras não podem ser selecionadas (BELGIU; DRĂGU, 2016).

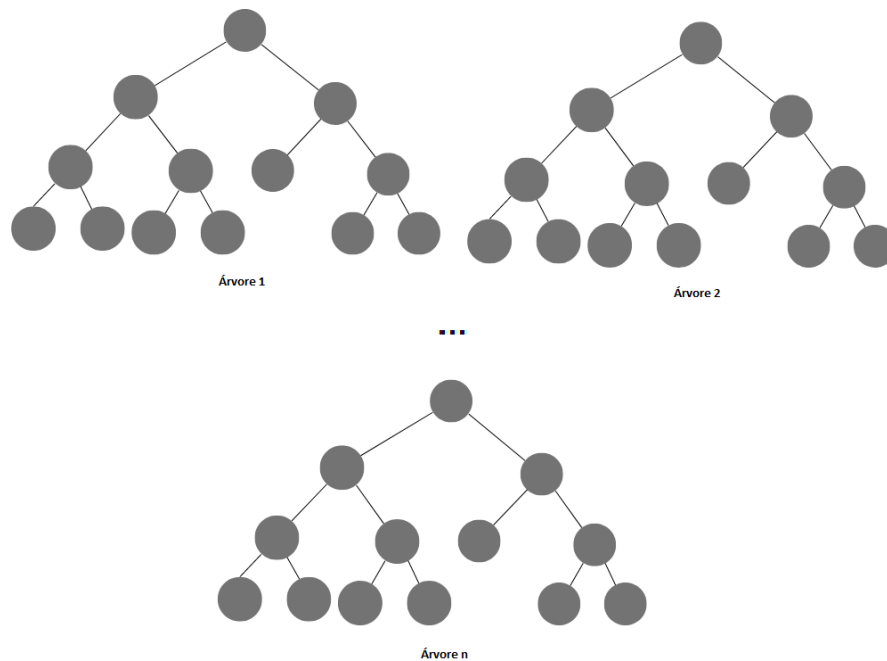
A decisão da classificação final é tomada pela média aritmética da classe de probabilidades de atribuição calculadas por todas as árvores produzidas. Com isso, uma nova entrada de dados é avaliada em relação a todas as árvores de decisão criadas no grupo e cada árvore vota para uma associação de classes. A classe de membros com o máximo de votos será finalmente selecionada (BELGIU; DRĂGU, 2016).

Logo, o algoritmo *Random forest* é constituído basicamente em um conjunto de árvores treinadas aleatoriamente para que sejam as mais independentes possíveis, com o objetivo de melhorar a robustez e a generalização do conjunto (BREIMAN, 2001).

Sendo este, configurado em um código *Java Script*, de classificação automática, que gera árvores de decisão (Figura 2). Segundo Breiman, (2001) esse classificador é baseado no princípio de árvores de decisão, onde sub-amostras são escolhidas de forma aleatória com repetição sendo assim utilizadas como variáveis preditivas para treinamento do classificador. Um diversificado

número de árvores é definido na etapa de treinamento, combinando-as para se ter uma predição com maior acurácia e estabilidade. Cada árvore é ligada a um vetor de características x e amostrado de forma independente e com a mesma distribuição para todas as árvores da floresta. A classe mais votada, a classificação, ocorre selecionando-se a vencedora de acordo com o número de votos acumulados.

Figura 2 - Exemplificação de como são definidas as árvores de decisão do algoritmo *Random forest*.



Fonte: do autor (2022).

Durante a execução do algoritmo são definidos que 70% das amostras serão utilizadas para a classificação da cobertura do solo e 30% das amostras serão utilizadas para a geração da acurácia da classificação. Nesses 30%, o algoritmo realiza a distribuição aleatória de pontos amostrais em polígonos pré-definidos e coletados para cada classe de cobertura do solo, a partir desses pontos obtém-se as medidas de acurácia.

2.4 Medidas de acurácia

Para a validação de mapeamentos temáticos é necessário que inicialmente se defina os termos acurácia, precisão e exatidão. Husch *et al.* (1982) definem precisão como o grau de

concordância de uma série de observações ou medidas, sendo associada aos erros aleatórios ou acidentais. Está diretamente ligada com a dispersão da distribuição das observações, ou seja, expressa o grau de consistência da grandeza medida com sua média, sendo atrelada à proximidade das suas informações em relação a si mesma, quanto mais próximas estas observações, mais precisas (MONICO et al., 2009).

Andrade (2003) apresenta exatidão como sinônimo de acurácia. A falta de exatidão das observações pode ser oriunda dos erros sistemáticos e tendem a se acumular em um mesmo sentido. É possível que uma amostragem possua alta precisão e ao mesmo tempo, devido à falta de exatidão, um grau inferior de acurácia.

Segundo Stehman e Wickham (2011), as medidas de acurácia são definidas como um componente do processo de criação e distribuição de mapas temáticos. Em estudos de sensoriamento remoto são adotadas para avaliar a qualidade do mapa temático, representado pela classificação de saída. As medidas de acurácia têm outros objetivos, como descrever os padrões espaciais dos erros de classificação, medir os efeitos das condições ambientais, selecionar o melhor mapa de cobertura do solo para uma dada área ou região e comparar diferentes técnicas de mapeamento (STEHMAN, 2000).

Para avaliação final da qualidade de um mapa temático de cobertura do solo, é usada a avaliação da acurácia, um processo específico de mensuração dos dados, com o objetivo de comparar mapas. Avaliação de precisão é uma comparação, base fundamental, de localização específica entre o mapa temático gerado e a condição do terreno, chamado de dado de referência (FOODY, 2002; STEHMAN, 2000; STEHMAN; WICKHAM, 2011).

Por meio das informações de referência representando as condições de campo, realiza-se a descrição dos erros da classificação com a confecção da matriz confusão (CONGALTON et al., 2019). A matriz confusão apresenta os resultados da classificação digital, ou seja, as informações de referência cruzadas com as informações apresentadas pela classificação, que é composta por um quadro de linhas (referência) e colunas (classificação) (ANTUNES; LINGNAU, 1997).

Os dados da amostra são frequentemente resumidos na matriz confusão. A diagonal central da matriz representa o acerto de pixels amostrados em relação aos dados de verdade de campo. O somatório dos valores da diagonal principal, dividido pelo número total de pixels obtidos, resulta no valor da acurácia global (ANTUNES; LINGNAU, 1997).

A acurácia global é obtida com base na matriz confusão e avalia a precisão do classificador. Segundo (WATZLAWICK, 2003) esse valor representa a relação entre os pontos classificados corretamente e o número total de pontos amostrais utilizados. Ainda segundo estes autores a acurácia global representa a precisão de todo o mapeamento, não indicando, por meio das classes individuais, como a precisão está distribuída.

Também se obtém da matriz confusão outras medidas de precisão (FOODY, 2009). A precisão das classes individuais, o percentual de casos corretamente classificados para cada classe quando comparado com o número total de casos dessa classe, resulta na comparação das classes individuais, que pode ser realizada a partir de dois pontos de vista, que são as acurácias do produtor e do usuário (JANSSEN; WEL, 1994). A partir da matriz confusão também se obtém o Índice Kappa.

A acurácia do produtor está relacionada à porcentagem de pontos de determinada classe que foram corretamente classificados em relação a totalidade dos pixels de referência, ou seja, a porcentagem dos pontos de verdade de campo de uma classe que esta corretamente classificada no mapa. (ANTUNES; LINGNAU, 1997). A porcentagem das amostras de referência desta classe que não foram corretamente classificadas pertencem ao erro de exclusão ou omissão.

A acurácia do usuário está relacionada aos erros de inclusão ou comissão que estão atribuídos a todos os pontos relacionados a uma determinada classe, oriundos de erros de classificação de outras classes, indicando a probabilidade de um alvo classificado representar a mesma classe em campos (BRITO, 2008).

O índice Kappa (Tabela 1), avalia a quantidade de amostras corretamente classificadas que correspondem à razão entre essas amostras (soma da diagonal principal da matriz confusão) e o número total de amostras (soma de todos os elementos dessa matriz) sendo o número total de classes a referência (COHEN, 1960).

Tabela 1 - Interpretação da qualidade da classificação de cobertura do solo de acordo com os valores do Índice Kappa.

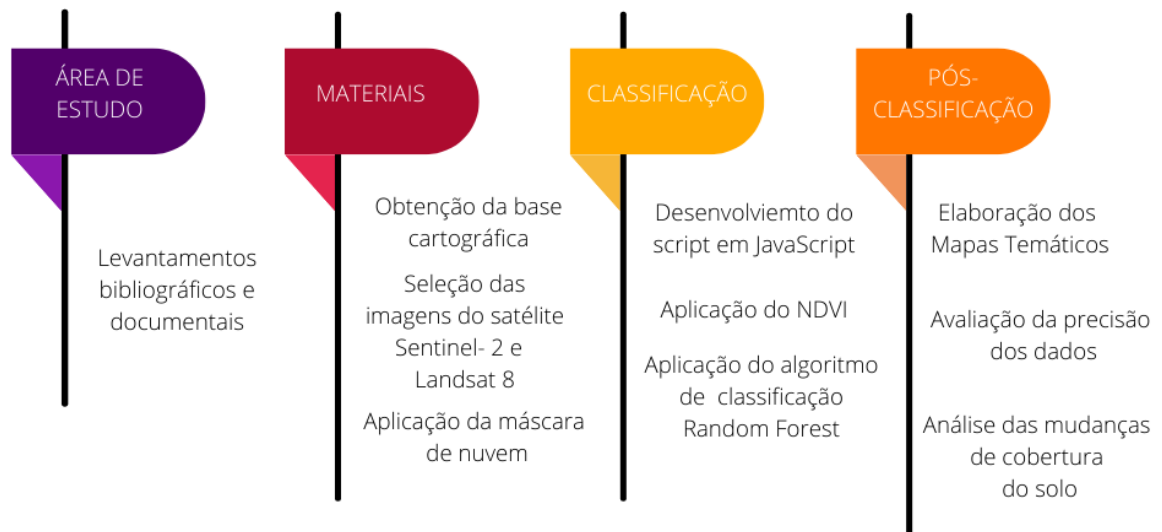
ÍNDICE KAPPA	QUALIDADE DA CLASSIFICAÇÃO
0,00	Péssimo
0,01 a 0,20	Ruim
0,21 a 0,40	Razoável
0,41 a 0,60	Boa
0,61 a 0,80	Muito Boa
0,81 a 1,00	Excelente

Fonte: LANDIS; KOCH (1977), do autor (2022).

3 MATERIAIS E MÉTODOS

As etapas da metodologia estão organizadas em sequência de processamento de acordo com a Figura 3.

Figura 3 - Fluxograma com a sequência de processamento das etapas da metodologia desenvolvida.



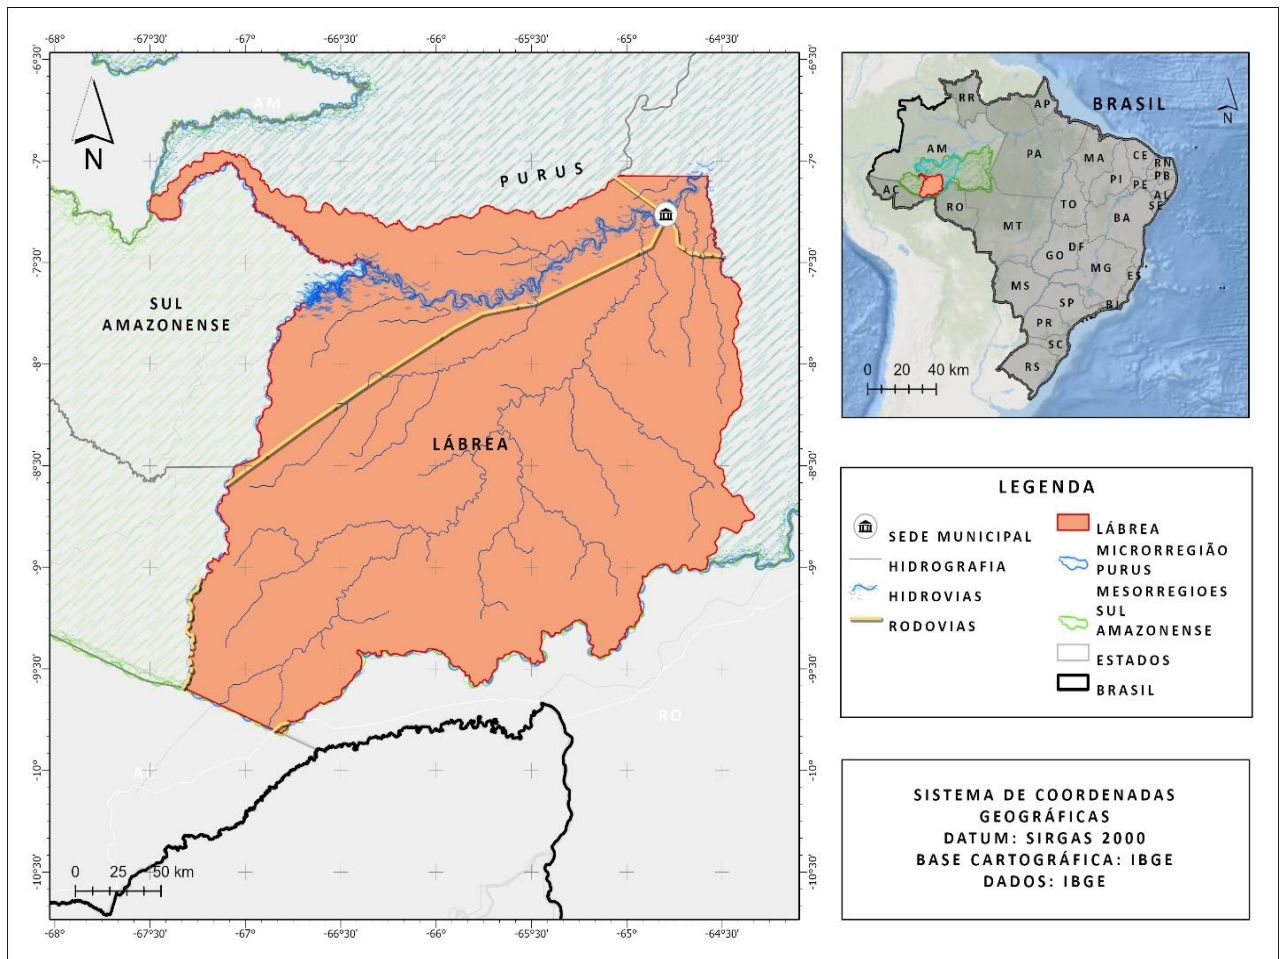
Fonte: do autor (2022).

3.1 Área de estudo

A área de estudo deste trabalho é o município de Lábrea, localizado na mesorregião do Sul Amazonense e na microrregião de Purus, com uma extensão territorial de 68.262,680 km², e com

uma população de 47.685 pessoas (IBGE, 2021). Localizado as margens do Rio Purus nas coordenadas geográficas 07°15'32" de latitude Sul e 64° 47' 52" de longitude a Oeste (Figura 4), limite com os municípios de Boca do Are, Pauini, Canutama e Tapauá além dos Estados de Rondônia e Acre.

Figura 4 - Mapa de localização da área de estudo, município de Lábrea, pertencente ao estado do Amazonas.



Fonte: do autor (2022).

De acordo com Köppen e Geiger o clima predominante é o do Grupo A, Clima Tropical chuvoso, e tipos climáticos Af, caracterizado pelo tropical úmido e superúmido, sem estação seca e Am, caracterizado por chuvas de tipo monção (BRASIL,1978). A vegetação é composta por Floresta ombrófila aberta, Floresta ombrófila densa, Savana, e áreas de formações pioneiras. (IBGE, 2005; IBGE, 2010).

O município de Lábrea, segundo dados do PRODES (2022), é um dos municípios do estado do Amazonas com o maior índice de desmatamento, sendo os anos de 2020 e 2021 com as maiores áreas desmatadas desde 2008. O ano de 2020 apresentou uma área correspondente a 382,87 km² de incremento de desmatamento, e o ano de 2021 uma área de 540,23 km². A região sofre com inúmeros conflitos de terras, entre eles a forte pressão de grileiros, pelo fato do município estar ligado a BR 364, que é uma das principais rotas do desmatamento. Por meio da retirada ilegal de madeira ao Sul do município, a BR 364 dá acesso a estradas secundárias ou clandestinas que conecta as capitais Porto Velho (RO) e Rio Branco (AC) (FRANCO, 2010).

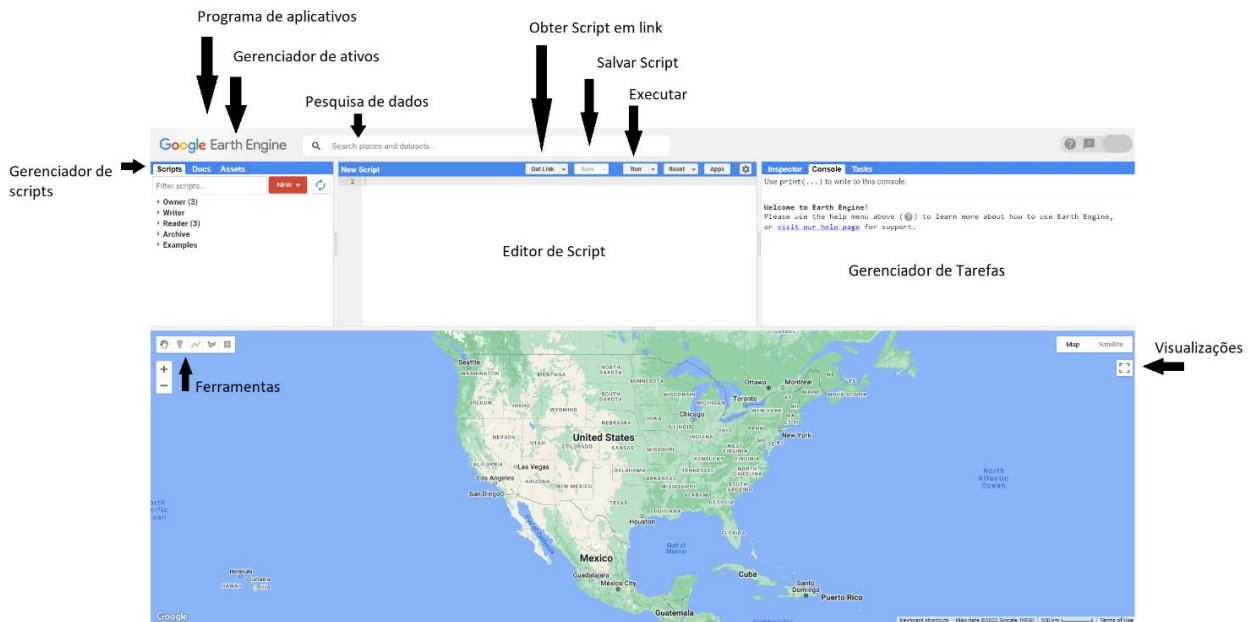
3.2 Obtenção e pré-processamento das imagens

Com os dados de desmatamento disponibilizados pelo PRODES (2022) foram definidos os anos a serem feitas as classificações da cobertura do solo. Sendo definidos aqueles que apresentaram maior incremento de desmatamento para a área de estudo: 2020 e 2021.

A base cartográfica utilizada foi obtida em formato digital *shapefile* disponibilizado pelo Instituto Brasileiro de Geografia e Estatística (IBGE, 2021).

A obtenção e pré-processamento das imagens foram feitas utilizando o *Code Editor* do GEE (Figura 5) a partir dos *scripts* desenvolvidos.

Figura 5 - Layout do Code Editor do Google Earth Engine onde se elabora os scripts e visualiza-se os produtos obtidos.



Fonte: do autor (2022)

Para produção do mapa de cobertura do solo do município de Lábrea foi criado um banco de dados geográficos com o objetivo de estruturar uma análise elaborada para essa pesquisa. Sendo assim, foram utilizados dados disponibilizados em nuvem na plataforma do GEE de imagens do satélite USGS Landsat 8 Level 2, Collection 2, Tier 1, OLI/TIRS (*ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")*), usadas para coleta das amostras de treinamento do algoritmo classificador e obtenção do índice de vegetação, que foram utilizados na realização da classificação de cobertura do solo, para os anos de 2020 e 2021. Nestas imagens foram aplicadas uma máscara de nuvens nas bandas SR_QA_AEROSOL Bitmask com o objetivo de reduzir a interferência causada pelas nuvens (Figura 6). No *script* é aplicado esta função de mascarar, presente dentro da memória da plataforma do GEE, possibilita a aplicação de um filtro de nuvens que promove a redução ou até mesmo a remoção dos ruídos causados por nuvens com o objetivo de diminuir a interferência de pixels contaminados e assim retornar apenas imagens “limpas”, livres de contaminação por nuvens, apresentando uma boa qualidade de interpretação. Também foi incluído o cálculo dos índices de vegetações NDVI, EVI, NDWI, NDWI_VEG e MNDWI, para serem inclusos na composição das bandas da imagem Landsat 8 e serem usados como bandas auxiliares na classificação da cobertura do solo.

Figura 6 - Trecho do script onde se define a área de estudo, a coleção das imagens Landsat 8 e aplicação da máscara de nuvens. (continua)

```

//// DEFININDO A ÁREA DE ESTUDO ////
// Importar shape para definir a ROI

var area_estudo = ee.FeatureCollection('users/mardydelgado/Labrea')

var empty = ee.Image().byte();
// Contorno da Imagem
var contorno = empty.paint({
  featureCollection: area_estudo,
  color: 1,
  width: 2
});

Map.addLayer(contorno, {palette: 'Black'}, 'Município de Lábrea');
Map.setOptions("HYBRID")
Map.centerObject(area_estudo,10)

/***** APLICANDO UMA MÁSCARA DE NUVENS NA
COLEÇÃO LANDSAT *****/
function maskL8sr(image) {
  // Bit 0 - Fill
  // Bit 1 - Dilated Cloud
  // Bit 2 - Cirrus
  // Bit 3 - Cloud
  // Bit 4 - Cloud Shadow
  // Bit 5 - Snow
  var qaMask = image.select(['QA_PIXEL']).bitwiseAnd(parseInt('11111',2)) //analisar
    .eq(0) //2 = Cirrus //eq=0 Condições claras
  var saturationMask = image.select("QA_RADSAT").eq(0) //Radiometric saturation QA

  //Aplique os fatores de escala às bandas apropriadas.
  var opticalBands = image.select("SR_B.").multiply(0.0000275).add(-0.2)
  var thermalBands = image.select("ST_B.*").multiply(0.00341802).add(149.0)

  //Substitua as bandas originais pelas escalonadas e aplique as máscaras.
  return image
    .addBands(opticalBands, null, true)
    .addBands(thermalBands, null, true)
    .updateMask(qaMask)
    .updateMask(saturationMask)
}

```

Figura 6 - Trecho do script onde se define a área de estudo, a coleção das imagens Landsat 8 e aplicação da máscara de nuvens. (conclusão)

```

/***** IMPORTANDO A COLEÇÃO LANDSAT 8 2020
*****/
var l8 = ee.ImageCollection("LANDSAT/LC08/C02/T1_L2")
    .filterDate('2020-07-01','2020-10-31')
    .filterBounds(area_estudo)
    .filterMetadata('CLOUD_COVER','less_than',5)
    .map(maskL8sr)

print('1 - Coleção Landsat 8_2020', l8)
print('2 - Quantas imagens estou utilizando?',l8.size())

//Adicionando Layers
Map.addLayer(l8.median().clip(area_estudo),{bands: ['SR_B4', 'SR_B3', 'SR_B2'], min: 0.0081,
max: 0.19},'L8_2020')

var l8_mosaic = l8.median().select('SR_B4', 'SR_B3', 'SR_B2').clip(area_estudo)
/***** Índices para coleção
*****/
function indices (image) {
  //Índices de Vegetação
  var ndvi = image.normalizedDifference(['SR_B5', 'SR_B4']).rename('NDVI');// Rouse 1973

  var evi = image.expression('2.5 * ((N - R) / (N + (6 * R) - (7.5 * B) + 1))',
  { //Huete 2002
    'N': image.select('SR_B5'), 'R': image.select('SR_B4'), 'B':
image.select('SR_B2')}).rename('EVI');

  //Índices de Água
  var ndwi = image.normalizedDifference(['SR_B3', 'SR_B5']).rename ('NDWI');//Mc Feeters
1996
  var ndwi_veg = image.normalizedDifference(['SR_B5', 'SR_B6']).rename ('NDWI_VEG');//Gao
1996
  var mndwi = image.normalizedDifference(['SR_B3', 'SR_B6']).rename('MNDWI');// Xu 2006

  return image.addBands([ndvi,evi,ndwi,ndwi_veg,mndwi]).clipToCollection(area_estudo)}

```

Fonte: do autor (2022).

Também utilizando os dados em nuvem do GEE, foram utilizadas imagens do satélite Sentinel-2 MSI: MultiSpectral Instrument, Level-2^a (*ee.ImageCollection* ("*COPERNICUS/S2_SR*")), usadas para coletar amostras para as medidas de acurácia, para maior precisão da verdade de campo. Assim como nas imagens Landsat 8, foi aplicada a máscara de nuvem para diminuição da interferência das nuvens na banda QA60 (Figura 7).

Figura 7 - Trecho do script onde se define a área de estudo, a coleção das imagens Sentinel-2 e aplicação da máscara de nuvens.

```

//// DEFININDO A ÁREA DE ESTUDO ////
// Importar shape para definir a ROI
var area_estudo = ee.FeatureCollection('users/rnardydelgado/Labrea')
var empty = ee.Image().byte();
// Contorno da Imagem
var contorno = empty.paint({
  featureCollection: area_estudo,
  color: 1,
  width: 2
});
Map.addLayer(contorno, {palette: 'Black'}, 'Município de Lábrea');
Map.setOptions("HYBRID")
Map.centerObject(area_estudo, 10)
/***** COLETANDO AMOSTRAS DE TREINAMENTO *****/
//// Função para mascarar nuvens usando a banda Sentinel-2 QA.
function maskS2clouds(image) {
  var qa = image.select('QA60')
  // Os bits 10 e 11 são nuvens e cirros, respectivamente.
  var cloudBitMask = 1 << 10;
  var cirrusBitMask = 1 << 11;
  // Ambos os sinalizadores devem ser definidos como zero, indicando condições claras.
  var mask = qa.bitwiseAnd(cloudBitMask).eq(0).and(
    qa.bitwiseAnd(cirrusBitMask).eq(0))
  // Retorne os dados mascarados e dimensionados, sem as bandas de controle de qualidade.
  return image.updateMask(mask).divide(10000)
    .select("B.*")
    .copyProperties(image, ["system:time_start"])
}
// Composição
var collection = ee.ImageCollection("COPERNICUS/S2_SR")
  .filterDate("2020-07-01", "2020-10-31")
  .filterBounds(area_estudo)
  .filterMetadata('CLOUDY_PIXEL_PERCENTAGE', 'less_than', 5) // avaliação de cobertura de nuvem
Map.addLayer(collection.median().clip(area_estudo), {bands: ['B4', 'B3', "B2"], min: 198, max:
1421}, 'SE_2020')
var SE_mosaic = collection.median().select('B4', 'B3', 'B2').clip(area_estudo)

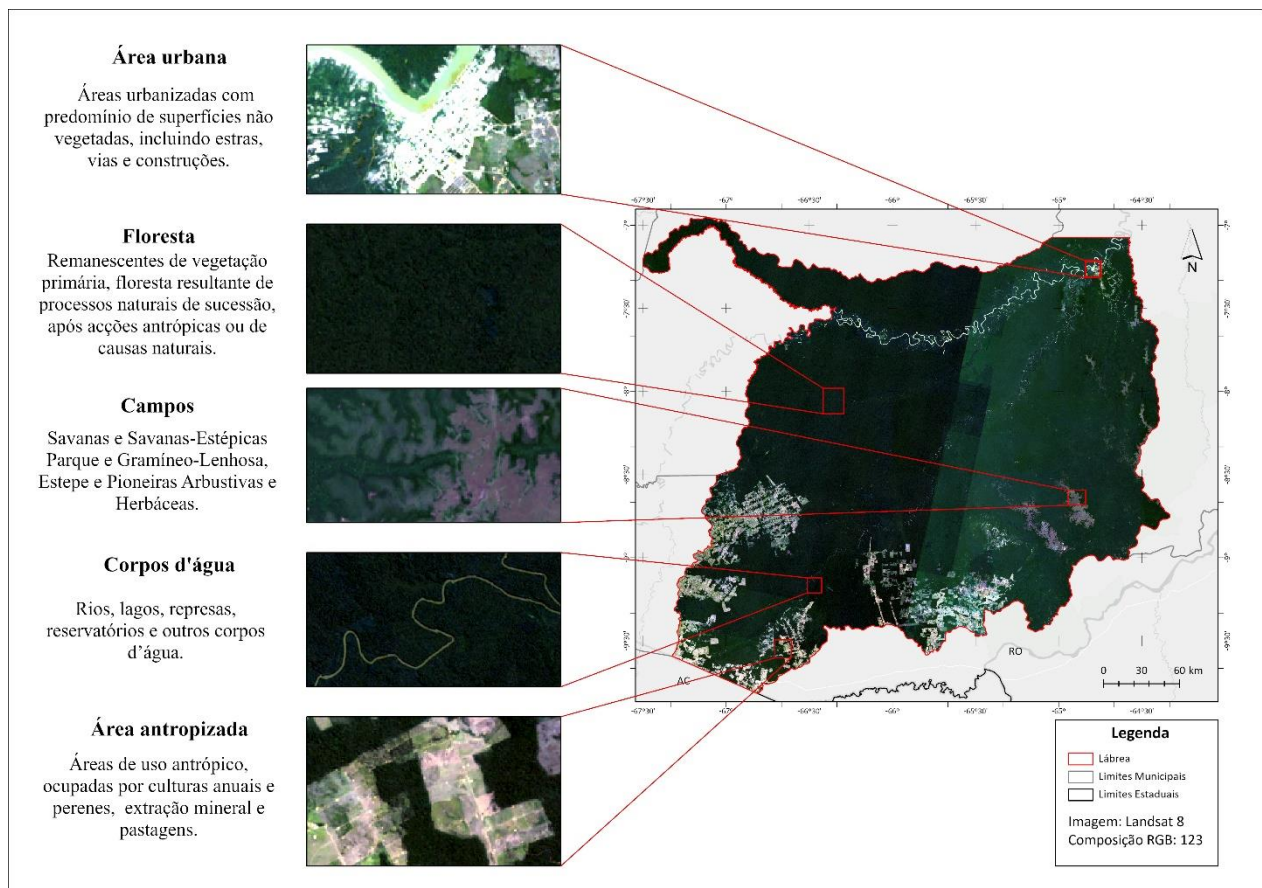
```

Fonte: do autor (2022).

3.3 Classificador *Random forest* e sua parametrização

Foi também desenvolvido o *script* para classificação de cobertura do solo na plataforma do GEE no *Code Editor* (Figura 9). Inicialmente foram coletadas as amostras representativas de cada classe temática a ser mapeada, 70% dessas amostras serão utilizadas para classificação da cobertura do solo, para a área de estudo, utilizando as imagens Landsat 8, tanto para o ano de 2020 quanto para o ano de 2021. Foram definidas 5 classes temáticas, baseadas na chave de interpretação disponibilizada pelo projeto MapBiomas, que tem como propósito mapear anualmente a cobertura e uso da terra do Brasil e monitorar as mudanças do território (MAPBIOMAS, 2019). Na Figura 8 abaixo observa-se as classes definidas assim como suas características.

Figura 8 - Definição e características das classes que serão usadas na classificação da cobertura do solo nas imagens Landsat 8 2020 e 2021.



Fonte: do autor (2022).

Figura 9 - Trecho do script de classificação da cobertura do solo utilizando as 5 classes definidas para mapeamento das imagens Landsat 8, tanto para 2020 quanto para 2021.

```

/*****Classificação de Imagens*****/
//Definindo a coleção
var composite = 18_indices.median() //aplicamos um redutor de mediana para termos os
"melhores" pixel.
//Bandas da classificação
var bands = composite.bandNames() //Lista no nome das bandas
print('5 - Bandas da coleção',composite )
//Criando as amostras
//Criando amostras
//sampleRegions - Converte cada pixel de uma imagem (em uma determinada escala) que
cruza uma
//ou mais regiões em um recurso, retornando-os como um FeatureCollection.
var amostrasVegetacao = composite.sampleRegions({
  collection: vegetacao,
  scale: 30,
  geometries: true
}).randomColumn('random').limit(1000, 'random', false)
var amostrasCampos = composite.sampleRegions({
  collection: campos,
  scale: 30,
  geometries: true
}).randomColumn('random').limit(1000, 'random', false)
var amostrasAgua = composite.sampleRegions({
  collection: agua,
  scale: 30,
  geometries: true
}).randomColumn('random').limit(1000, 'random', false)
var amostrasSoloexposto = composite.sampleRegions({
  collection: soloexposto,
  scale: 30,
  geometries: true
}).randomColumn('random').limit(1000, 'random', false)
var amostrasUrban = composite.sampleRegions({
  collection: urbana,
  scale: 30,
  geometries: true
}).randomColumn('random').limit(1000, 'random', false)
// Juntando as amostras em uma única feature
var labels = amostrasVegetacao.merge(amostrasCampos)
                                .merge(amostrasAgua)
                                .merge(amostrasSoloexposto)
                                .merge(amostrasUrban)
//Adicionando uma coluna com valor aleatório na coleção de amostras
labels = labels.randomColumn('random')
// Sobreponha os pontos nas imagens para obter treinamento.
var data = composite.select(bands).sampleRegions({
  collection: labels,
  properties: ['classe'],
  scale: 30
});
// Ajuste o parâmetro minLeafPopulation.
var training = labels.filter(ee.Filter.lt('random', 0.7));
var testing = labels.filter(ee.Filter.gte('random', 0.7));

```

Fonte: do autor (2022).

Para a calibração do algoritmo classificador *Random forest*, com relação aos números de árvores que serão executadas, usa-se da função dos hiperparâmetros de Tuning, que é uma técnica que consiste em testar diferentes combinações exaustivamente e separar a melhor. Esses hiperparâmetros tendem a permanecerem constantes durante o trabalho e contém dados que controlam o próprio processo de treinamento. O treinamento é realizado pelo *AI Platform Training* que rastreia os resultados de cada teste fazendo ajustes nas avaliações posteriores, que criam um gráfico de parcimônia de todos os testes realizados juntamente com a configuração de valores que resultarão nos valores mais eficazes de acordo com o critério escolhido, baseado no número de árvores em que se obterá a melhor precisão. Para treinar o algoritmo, usou-se polígonos aleatórios para cada uma das 5 classes de mapeamento da cobertura do solo das imagens do satélite Sentinel-2 (Figura 10).

Figura 10 - Trecho do script em que se aplica os hiperparâmetros para calibração do número de árvores a serem executados pelo algoritmo Random forest.

```

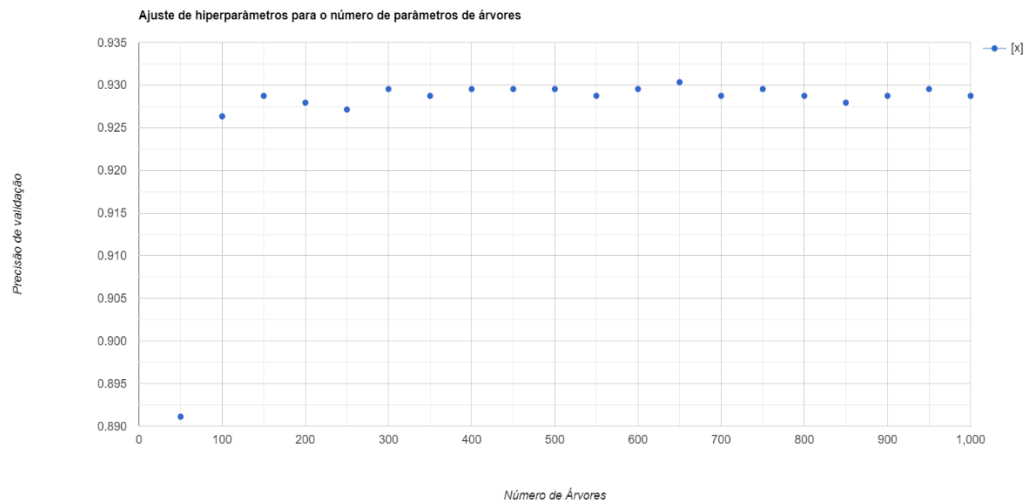
//*****
// Hyperparameter Tuning
//*****
// Train a classifier.
var classifier = ee.Classifier.smileRandomForest(50)
.train({
  features: training,
  classProperty: 'classe',
  inputProperties: bands
});
var test = composite.sampleRegions({
  collection: testing,
  properties: ['classe'],
  scale: 30,
  tileScale: 16
});
// Ajuste o parâmetro de número de árvores.
var numTreesList = ee.List.sequence(50, 1000, 50);
var accuracies = numTreesList.map(function(n) {
  var classifier = ee.Classifier.smileRandomForest({numberOfTrees:n,
  maxNodes:n})
  .train({
    features: training,
    classProperty: 'classe',
    inputProperties: bands
  });
  // Aqui estamos classificando uma table em vez de uma imagem
  // Classificadores funcionam em imagens e tabelas
  return test
  .classify(classifier)
  .errorMatrix('classe', 'classification')
  .accuracy();
});
var chart = ui.Chart.array.values({
  array: ee.Array(accuracies),
  axis: 0,
  xLabels: numTreesList
}).setOptions({
  title: 'Ajuste de hiperparâmetros para o número de parâmetros de árvores',
  vAxis: {title: 'Precisão de validação'},
  hAxis: {title: 'Número de Árvores', gridlines: {count: 15}}
});
print(chart)
/*****Aplicar a classificação de acordo com os parâmetros*****/
var trained = ee.Classifier.smileRandomForest({
  numberOfTrees: 650,
  //variablesPerSplit: 10,
  //bagFraction: 0.7,
  //minLeafPopulation: 2,
  seed: 123,
}).train(training,'classe',bands)
var classified = composite.classify(trained)
// Exibir as entradas e os resultados.
Map.addLayer(classified,
  {min: 0, max: 4, palette: ['#05a10a', '#90a15d', '#0b43f7', '#fff431', '#de2bff]},
  'Classificação RF');

```

Fonte: do autor (2022).

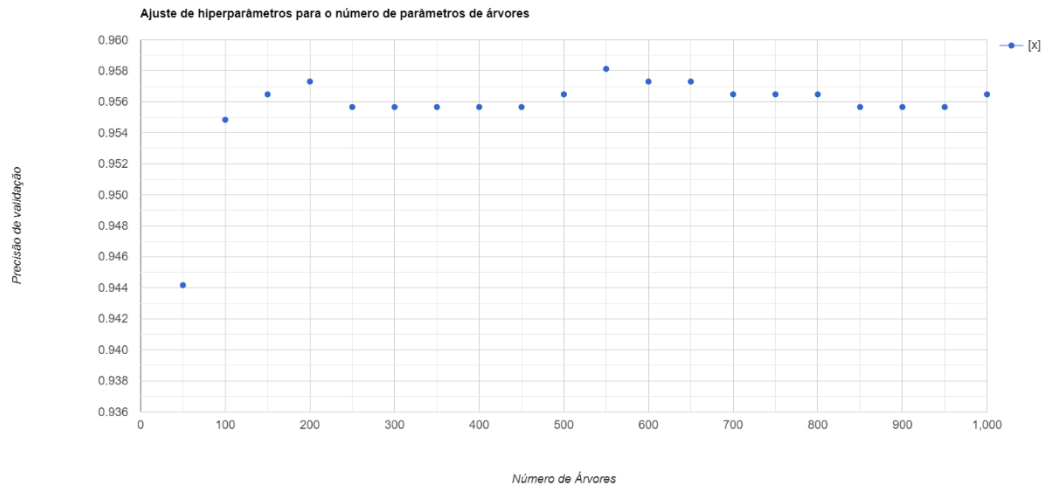
Nesta pesquisa, o classificador *Random Forest* foi executado a partir de 650 árvores de decisão para o ano de 2020 por apresentar uma melhor precisão para classificação, aproximadamente 93%, e 550 árvores para o ano de 2021 com uma precisão aproximada de 95,8%, como mostram as figuras 11 e 12 abaixo.

Figura 11 - Resultado da calibração do número de árvores a serem executados pelo algoritmo Random forest de acordo com a função do hiperparâmetro de Tuning, para uma classificação de cobertura do solo com melhor precisão, para o ano de 2020.



Fonte: do autor (2022).

Figura 12 - Resultado da calibração do número de árvores a serem executados pelo algoritmo Random forest de acordo com a função do hiperparâmetro de Tuning, para uma classificação de cobertura do solo com melhor precisão, para o ano de 2021.



Fonte: do autor (2022).

3.4 Análise da dinâmica da cobertura do solo

Com o objetivo de auxiliar na análise da dinâmica e classificação da cobertura do solo, foram incluídos no *script* alguns índices espectrais, que foram acrescentados nas imagens Landsat 8 como bandas, por meio de operações matemáticas entres os valores dos pixels das bandas das imagens. Os índices utilizados foram o Índice de Vegetação por Diferença Normalizada (NDVI), o Índice de Vegetação Melhorado (EVI), o Índice de Água de Diferença Normalizada (NDWI) e o Índice da Diferença de Água Normalizada Modificado (MNDWI) (Figura 13).

Figura 13 - Trecho do script em que se obtém os índices de vegetação através da imagem Landsat 8, para análise da dinâmica e classificação da cobertura do solo, para ambos os anos: 2020 e 2021.

```

/*****Índices para coleção *****/
function indices (image) {
  //Índices de Vegetação
  var ndvi = image.normalizedDifference(['SR_B5', 'SR_B4']).rename('NDVI');// Rouse 1973

  var evi = image.expression('2.5 * ((N - R) / (N + (6 * R) - (7.5 * B) + 1))',
  { //Huete 2002
    'N': image.select('SR_B5'), 'R': image.select('SR_B4'), 'B': image.select('SR_B2')}).rename('EVI');

  //Índices de Água
  var ndwi = image.normalizedDifference(['SR_B3', 'SR_B5']).rename ('NDWI');//Mc Feeters 1996
  var ndwi_veg = image.normalizedDifference(['SR_B5', 'SR_B6']).rename ('NDWI_VEG');//Gao 1996
  var mndwi = image.normalizedDifference(['SR_B3', 'SR_B6']).rename('MNDWI');// Xu 2006

  return image.addBands([ndvi,evi,ndwi,ndwi_veg,mndwi]).clipToCollection(area_estudo)}

/*****Aplicando os índices na coleção*****/
var l8_indices = l8.select("SR_B.").map(indices) //bandas B

```

Fonte: do autor (2022).

O NDVI, expresso pela Equação 1, é um índice que indica alterações na cobertura vegetal, apresentando alta sensibilidade para vegetações esparsas e vegetações mais densas, o que auxiliou na coleta de amostras para a classe Área Antropizada por evidenciar regiões que sofreram algum tipo de alteração. O NDVI é a combinação de informações espectrais da banda do vermelho e do infravermelho próximo, e é obtido através da expressão (ROUSE et al., 1974):

$$NDVI = \frac{NIR - Red}{NIR + Red} \quad (1)$$

O NDVI possui valores que possuem seu limiar entre -1 e 1, tendo seus valores positivos atribuídos a alvos como solos expostos, rochas e vegetação, possuindo refletância no vermelho e infravermelho próximo com intensidades próximas, e os alvos com valores de NDVI negativos refletem com mais intensidade no vermelho quando comparado ao infravermelho próximo, sendo atribuídos a rochas, corpos d'água ou neve (PAULA ASSUMPCÃO CORDEIRO et al., 2017). Para auxiliar na detecção de alteração da cobertura vegetal, foi aplicada uma operação de subtração de NDVIs nas imagens entre os anos de 2021 e 2020. Assim, valores maiores na imagem diferença, será indicativo da presença de vegetação e valores negativos presente nas regiões das imagens, será

indicativo de que houve algum tipo de alteração na vegetação. Regiões com valores próximos de zero irão corresponder as áreas onde houve pouca ou nenhuma alteração (LOURENÇO; LANDIM, 2004).

O índice NDWI tem por objetivo realçar e delinear automaticamente as águas abertas através da operação de bandas multiespectrais, expresso pela Equação 2. Combina as bandas do verde e do infravermelho próximo, gerando uma nova imagem, com valores de pixels variando de -1 a 1, sendo 0 o limiar entre alvos que são água e os que não são (MCFEETERS, 1996).

$$NDWI = \frac{Green - NIR}{Green + NIR} \quad (2)$$

O índice MNDWI, expresso pela Equação 3, substitui a banda do infravermelho próximo para o infravermelho médio, a fim de obter melhores resultados em regiões que possuem áreas construídas, visto que no NDWI estas se misturam com os corpos d'água, promove assim uma melhoria considerável na separação de alvos “água” e “não-água” (XU, 2006).

$$MNDWI = \frac{(Green - MIR)}{(Green + MIR)} \quad (3)$$

O EVI, Equação 4, busca otimizar o sinal da vegetação, intensificando a resposta em regiões de elevada concentração de biomassa, melhorando as interferências do solo e atmosféricas. (JUSTICE et al., 1998).

$$EVI = G * \frac{(NIR - RED)}{(NIR + C1 * RED - C2 * Blue + L)} \quad (4)$$

O uso destes índices acrescentados nas imagens como bandas, permitem ao classificador um maior poder de decisão durante a geração da classificação. Estes índices fornecem um maior realce das características, como vegetação e água, além daquelas fornecidas pelas bandas que compõem a imagem, como RGB e infravermelho. Logo irá permitir que o classificador obtenha resultados melhores.

3.5 Avaliação da classificação

Quando se trabalha com mapeamento derivado de dados de sensoriamento remoto há a necessidade de avaliação da precisão dos mesmos. Para análise dos dados obtidos deve existir a comparação com os dados tidos como verdade terrestre (RICHARDS, 2022). Os dados que representam as classes definidas de cobertura do solo devem ter a mesma localização de *pixel* que a imagem utilizada para a verdade de campo (JENSEN, 1986).

Assim, segundo Story e Congalton (1986), a forma mais utilizada de definição da precisão dos mapas e das imagens está na porcentagem da área do mapeamento que foi corretamente classificada com relação a verdade de campo. As amostras de acurácia foram coletadas de forma aleatória utilizando imagens Sentinel-2, para ambos os anos (2020 e 2021), por possuírem uma resolução melhor em comparação com as imagens Landsat 8. Ao todo foram coletados 4.194 pontos amostrais para as imagens dos dois anos, onde aproximadamente 2.935 pontos (70%) foram usados para gerar a classificação de cobertura do solo e aproximadamente 1258 pontos (30%) foram utilizados para a geração das acurácias (global, do produtor e do usuário) e da matriz confusão.

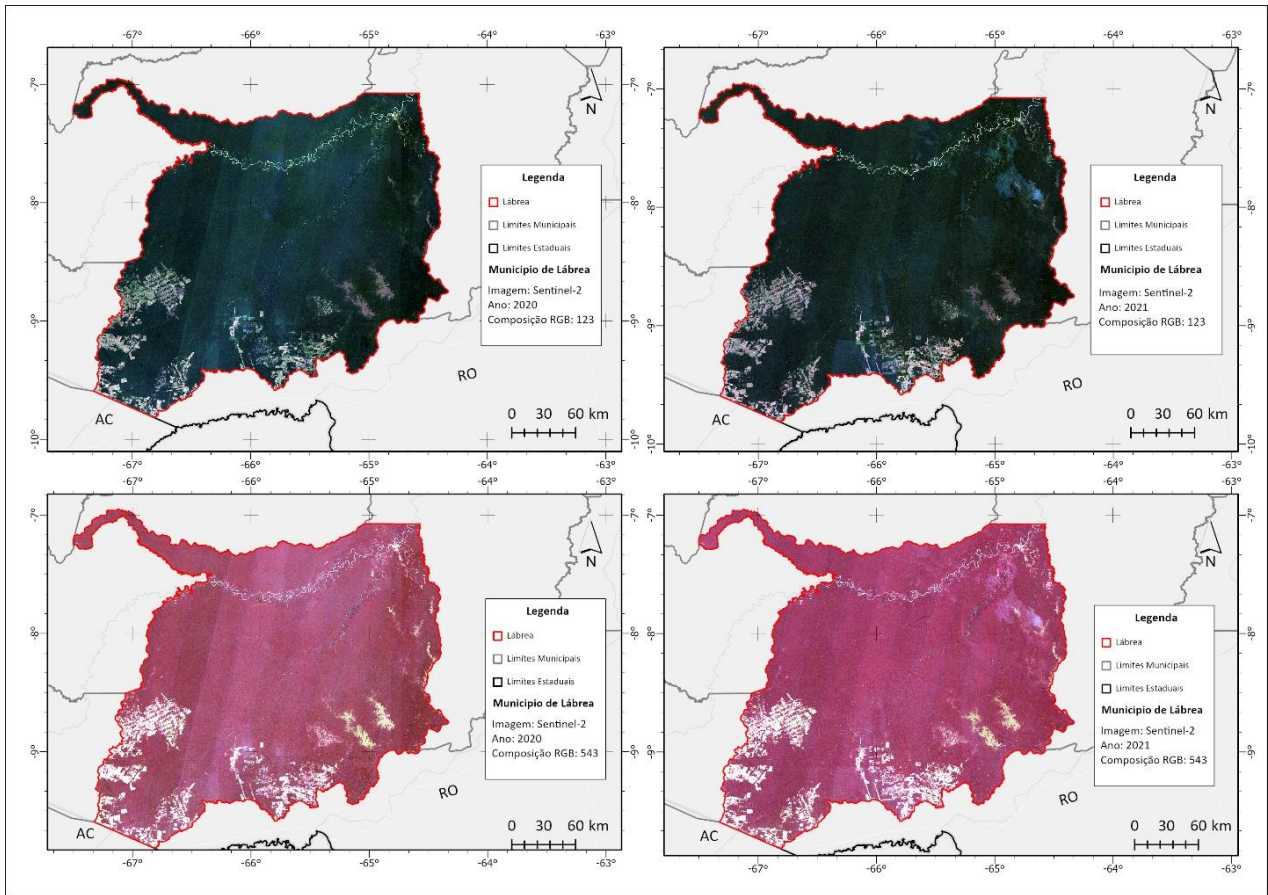
4 RESULTADOS E DISCUSSÕES

Com o desenvolvimento dos *scripts* na linguagem *JavaScript* dentro do Code Editor da plataforma GEE obteve-se as imagens do satélite Landsat 8 para o município de Lábrea para os anos de 2020 e 2021. O município está inserido em uma região que apresenta grande densidade de nuvens, o que afeta a identificação das classes que foram mapeadas, com isso a aplicação de filtros e máscaras se fez necessário para diminuir a contaminação dos pixels das imagens com nuvens. A utilização do mascaramento de nuvens fez com os pixels que tivessem presença de nuvens fossem descartados e devido ao grande volume de dados ao total de 26 (vinte e seis) imagens Landsat e 203 (duzentos e três) imagens Sentinel, para o ano de 2020; e 37 (trinta e sete) imagens Landsat e 263 (duzentos e sessenta e três) imagens Sentinel, para o ano de 2021, representando a área, houveram observações de todas as classes sem dificuldades.

A Figura 14 apresenta as imagens do satélite Sentinel-2 para os anos de 2020 e 2021, usadas para coleta das amostras de acurácia para cada classe mapeada, e a Figura 15 as imagens do satélite

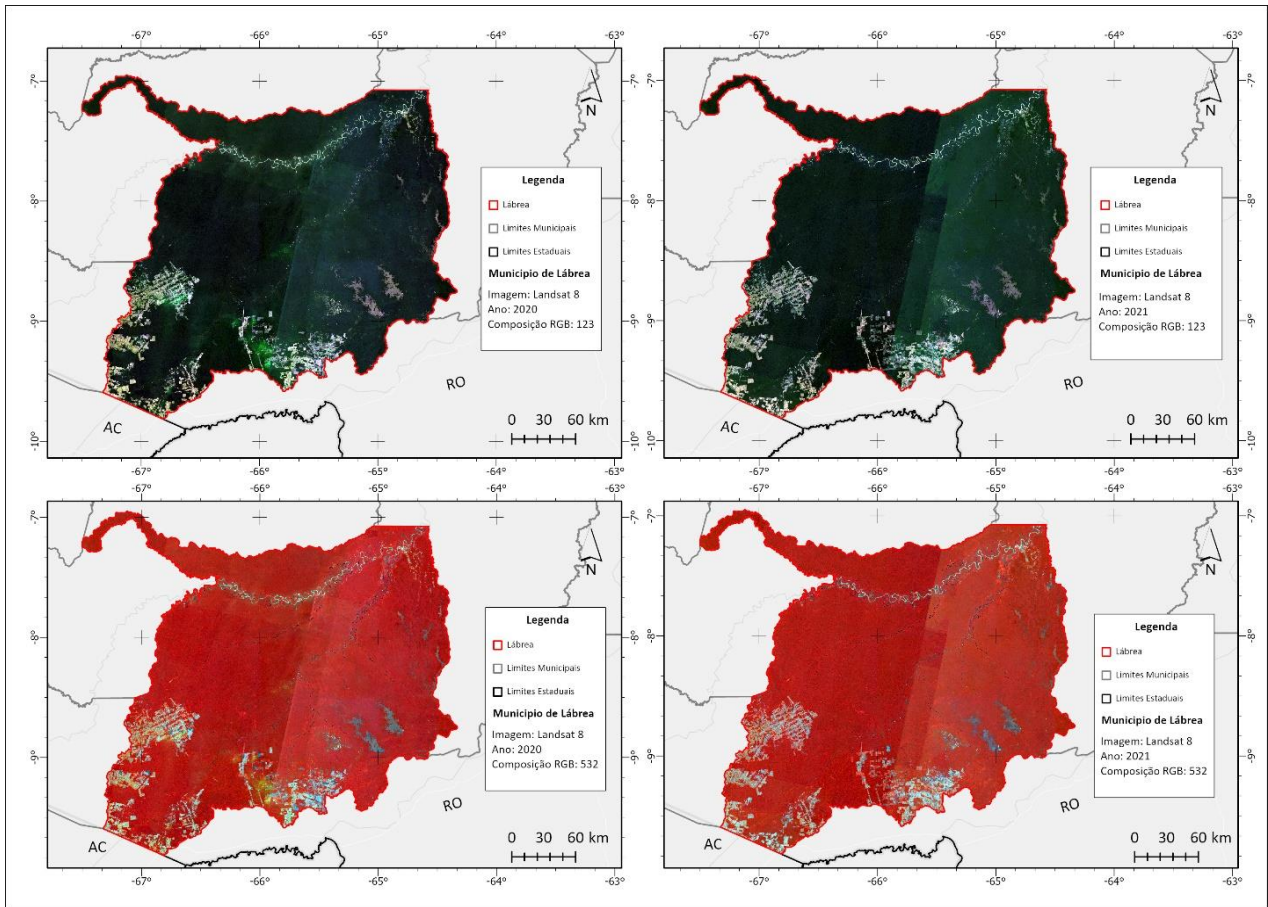
Landsat 8 OLI/TIRS para os anos de 2020 e 2021 usadas para a realização da classificação. As imagens são apresentadas na composição em cor verdadeira, falsa cor e contendo o filtro de remoção de nuvens.

Figura 14 - Imagens de satélite Sentinel-2 para a área de estudo, município de Lábrea, para os anos 2020 e 2021 nas composições de cor verdadeira e falsa cor.



Fonte: do autor (2022).

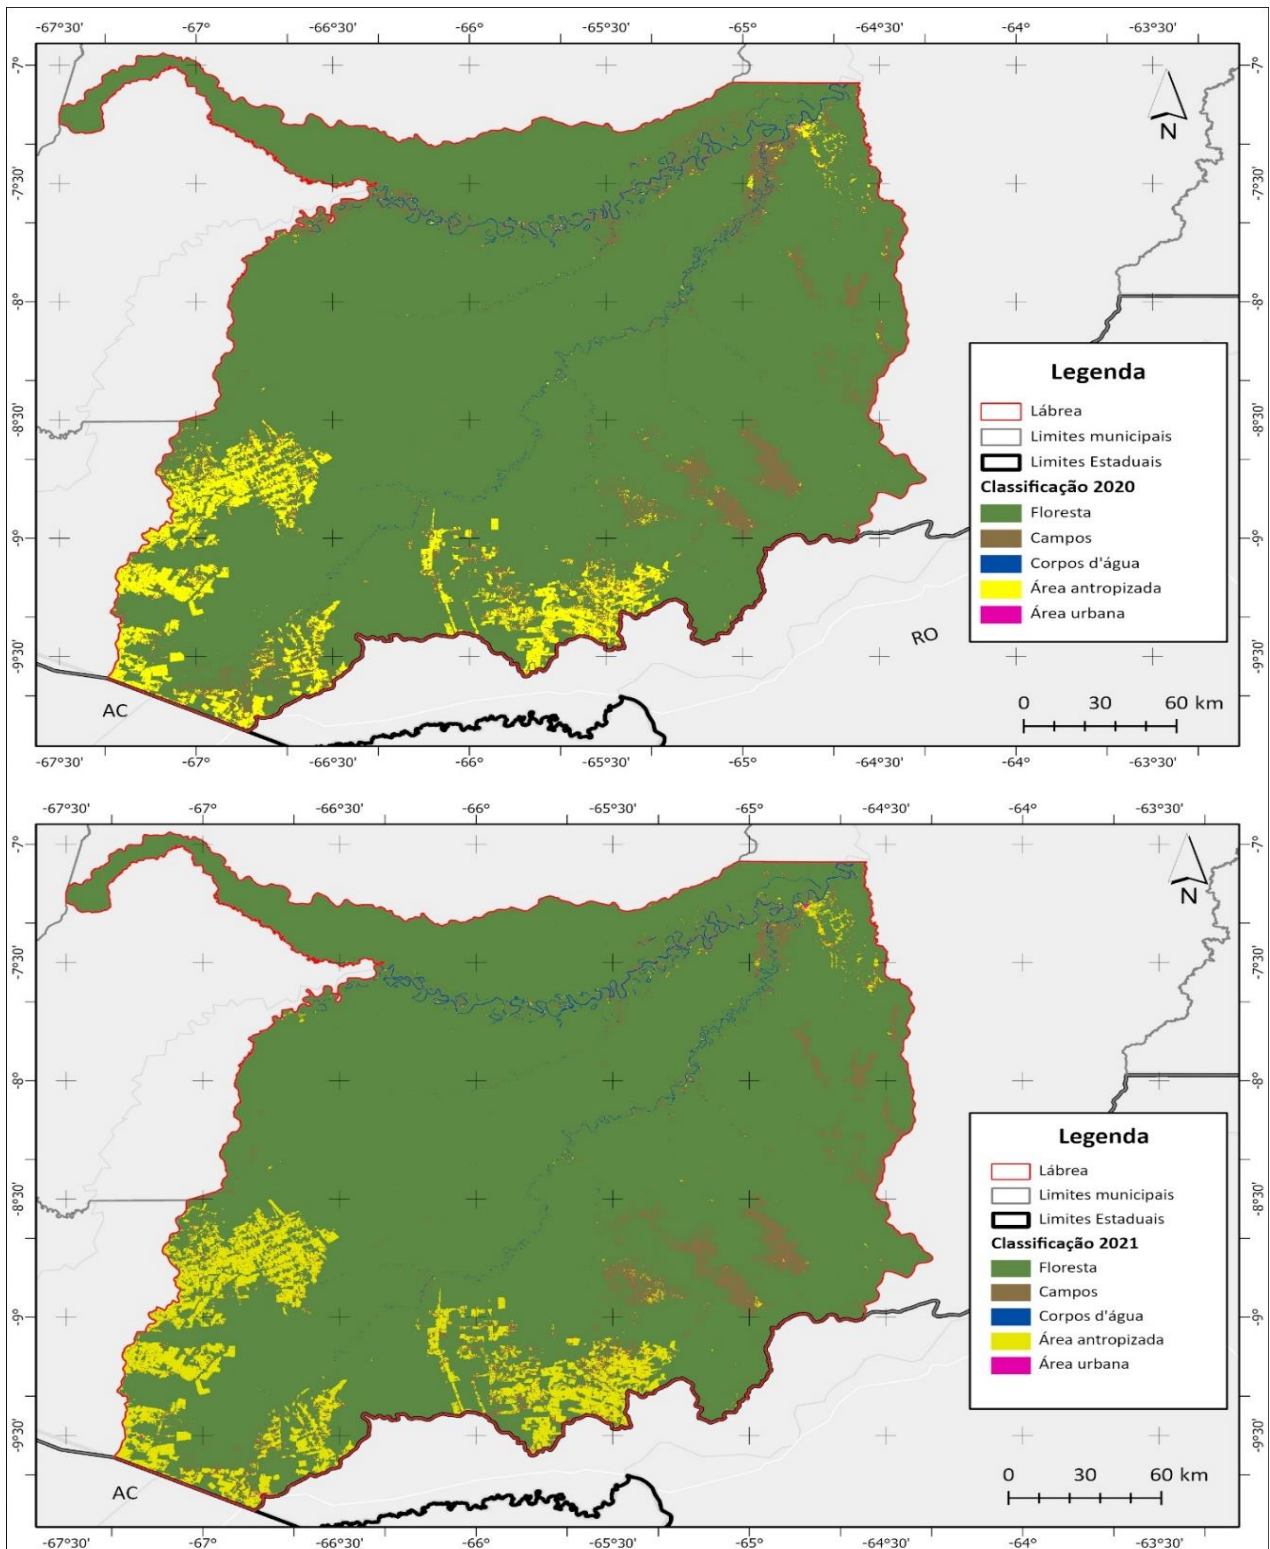
Figura 15 - Imagens de satélite Landsat 8 dos anos 2020 e 2021, para o município de Lábrea, área de estudo, nas composições de cor verdadeira e falsa cor.



Fonte: do autor (2022).

A partir do mapeamento das classes de cobertura do solo para o município de Lábrea para anos de 2020 e 2021 foi possível a elaboração dos mapas de classificação de cobertura do solo que podem ser visualizados na sequência, Figura 17, assim como os dados de área (em km²) para cada classe de mapeamento (Tabela 2). Tais resultados obtidos da classificação de cobertura do solo foram similares ao se visualizar os resultados do MapBiomass – coleção 6, para a área de estudo, selecionando-se as mesmas classes analisadas nesse estudo. Analisando as áreas das classes mapeadas foi possível observar, aproximadamente, 518,35 km² de áreas de formação natural que sofreram algum tipo de intervenção, natural ou antrópica, representando cerca de 0,75% da área do município, esse resultado ficou próximo ao valor de incremento de desmatamento disponibilizado pelo PRODES para o ano de 2021, que foi de 540,23 km².

Figura 16 - Resultado do mapeamento da classificação de cobertura do solo para a área de estudo, município de Lábrea, para os anos de 2020 e 2021.



Fonte: do autor (2022).

Tabela 2 - Resultado das áreas em km² das classes mapeadas da cobertura do solo para o ano de 2020 e 2021 para o município de Lábrea.

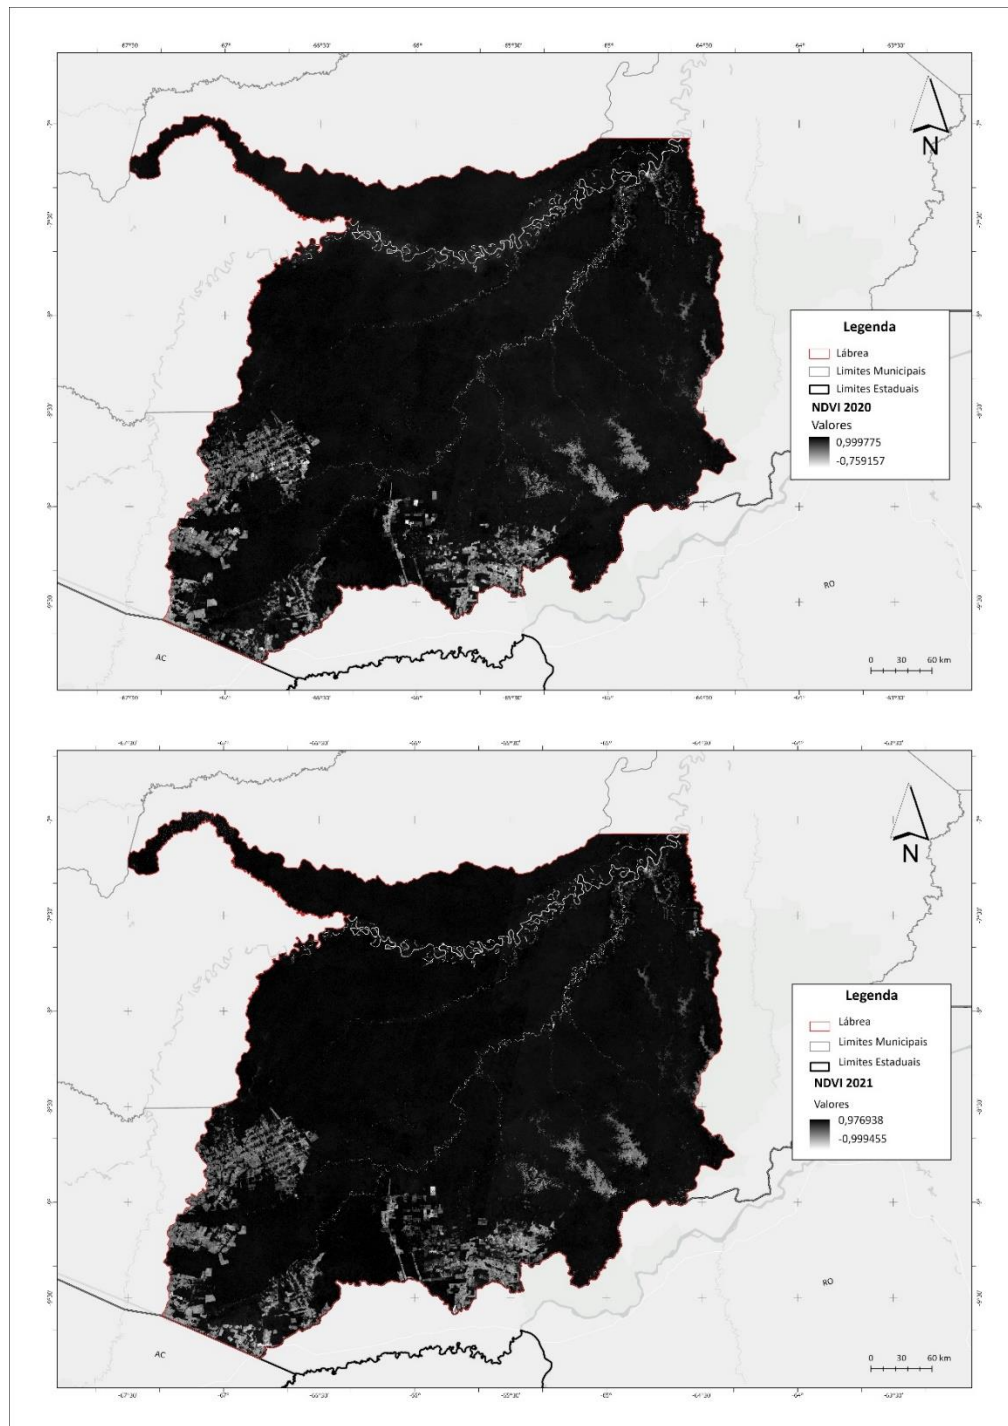
	2020	2021
CLASSE	ÁREA (km²)	ÁREA (km²)
Floresta	59.384,5	58.460,3
Campos	4.449,3	4.279,0
Corpos d'água	383,7	281,7
Área antropizada	4.025,5	5.215,5
Área Urbana	19,2	25,9
Total	68.262,2	68.262,4

Fonte: do autor (2022).

A Figura 17 representa dados de NDVI para anos de 2020 e 2021 que auxiliaram na classificação, na composição das bandas das imagens Landsat classificadas juntamente com os outros índices (EVI, NDWI, NDWI_veg e MNDWI), e na detecção de áreas que sofreram algum tipo de alteração. A Figura 18 mostra o NDVI diferença entre esses dois anos evidenciando as áreas que sofreram algum tipo de intervenção. A partir do NDVI diferença (2021-2020) foram definidas as áreas que sofreram alterações entre esses anos. As áreas que apresentam números positivos sofreram pouco ou nenhuma alteração, em geral área de pastagem. As áreas com números negativos representam áreas que sofreram alterações, regiões que sofreram desmatamentos, queimadas ou intervenções no solo. Valores que ficaram próximos de zero representam áreas que não sofreram nenhuma alteração, onde a vegetação se manteve sem nenhuma alteração entre esses anos. Essa técnica se mostrou eficiente por mostrar as condições da área de estudo em relação a vegetação. Segundo Aboud Neta et al. (2018), NDVI se mostrou um forte indicador de monitoramento, não só para caracterização da vegetação, como também para acompanhamento de expansão urbana e regiões com incidências de desmate ao longo dos anos, o que foi observado nesse estudo.

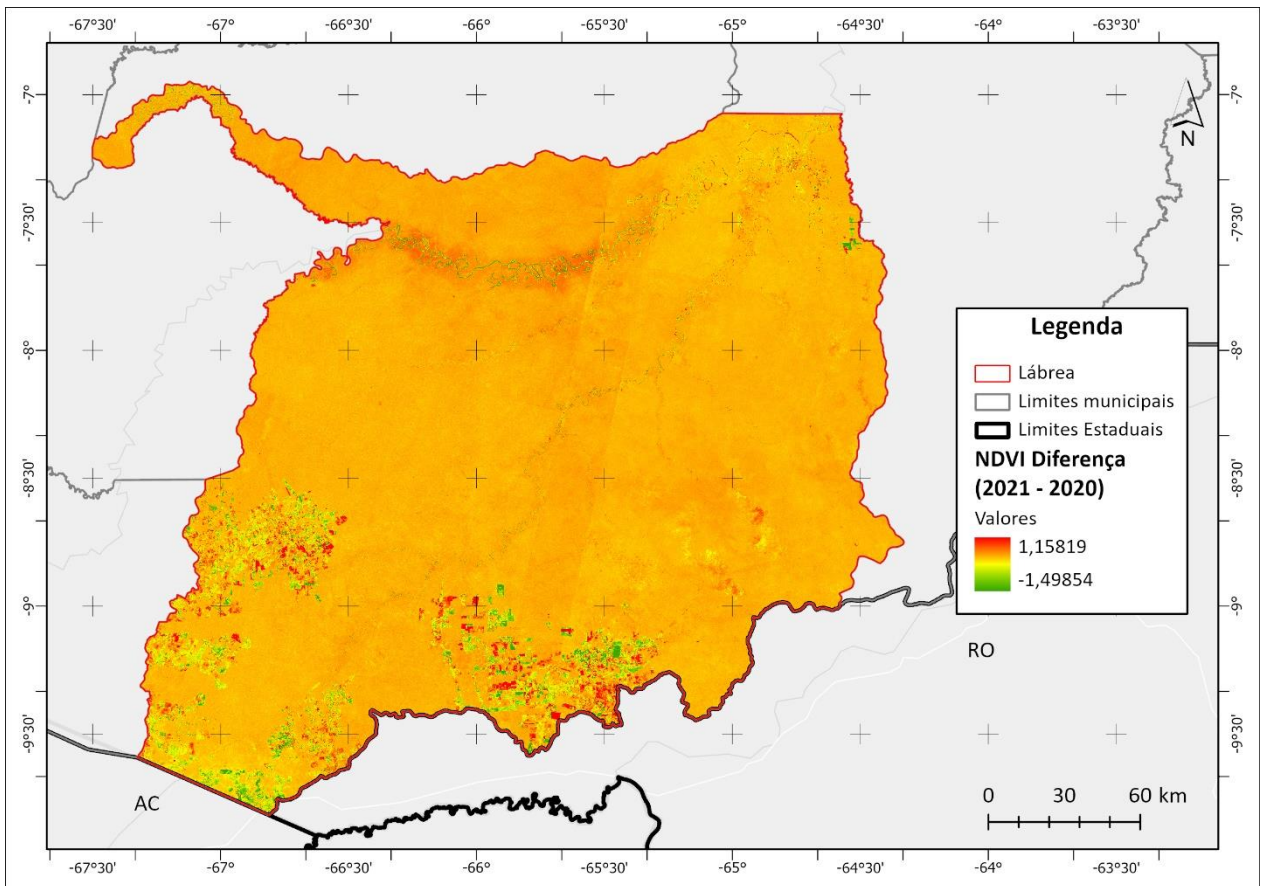
Observou-se que uso dos índices de vegetação incluídos como bandas das imagens Landsat, permitiram uma classificação mais precisa, por fornecer ao algoritmo mais características, além das fornecidas pelas bandas originais da imagem, durante o mapeamento das classes.

Figura 17 - Índice de vegetação NDVI, para anos 2020 e 2021, do município da área de estudo, Lábrea.



Fonte: do autor (2022).

Figura 18 - Índice de vegetação NDVI diferença, entre os anos de 2021 e 2020, para o município de Lábrea, área de estudo.



Fonte: do autor (2022).

Com o auxílio do NDVI diferença identificou-se as áreas que sofreram algum tipo de alteração. Segundo Porto Chaves et al. (2014), o uso de índices de vegetação podem ser usados com um alto grau de confiabilidade, sobretudo o NDVI, como foi constatado neste estudo.

Para análise da precisão do mapeamento realizado é utilizada a matriz confusão (Tabela 3 e Tabela 4). Da sua análise é possível obter os valores das acurácias global, do produtor e do usuário. Observou-se que de um total de 1.267 pontos distribuídos aleatoriamente sobre o mapeamento de cobertura do solo para o ano de 2020, ou seja, aproximadamente 30% dos 4.194 pontos distribuídos para geração das acurácias, na imagem de satélite Sentinel-2, utilizada como referência (verdade de campo), 1.182 pontos se mostram condizentes com a classificação.

Tabela 3 - Resultados da matriz confusão gerados do mapeamento da classificação de cobertura do solo para o ano de 2020 do município de Lábrea.

Referência Classificação	Floresta	Campos	Corpos d'água	Área antropizada	Área urbana	TOTAL	INCLUSÃO (%)
Floresta	300	1	0	0	0	301	93
Campos	16	283	0	12	1	312	87,73
Corpos d'água	0	1	307	1	2	311	98,63
Área antropizada	1	40	1	235	1	278	92,8
Área urbana	0	0	7	1	57	65	93,22
TOTAL	317	325	315	249	61	1182	
OMISSÃO (%)	98,93	88,57	96,98	88,35	90,16		

Fonte: do autor (2022).

Os resultados obtidos da matriz confusão para o ano de 2021 (Tabela 4) permite observar que de um total de 1.242 pontos (aproximadamente 30% dos 4.194 pontos amostrais) distribuídos aleatoriamente sobre a imagem de satélite Sentinel-2 para o ano de 2021, 1.184 pontos se mostram concordantes com a classificação.

Tabela 4 – Matriz confusão da classificação de cobertura do solo para o ano de 2021 do município de Lábrea.

Referência Classificação	Floresta	Campos	Corpos d'água	Área antropizada	Área urbana	TOTAL	INCLUSÃO (%)
Floresta	293	8	0	1	0	302	93
Campos	8	277	2	8	1	296	87,73
Corpos d'água	0	0	285	3	3	291	98,63
Área antropizada	1	14	0	283	1	299	92,8
Área urbana	0	0	2	2	51	55	93,22
TOTAL	302	299	289	297	56	1189	
OMISSÃO (%)	98,93	88,57	96,98	88,35	90,16		

Fonte: do autor (2022).

A acurácia global do mapeamento, expressa pela razão entre o total de pontos de referência e os pontos corretamente classificados foi de 93,3% para o ano de 2020 e de 95,3% para o ano de 2021. O índice Kappa foi de 0,91 para 2020 e 0,94 para 2021, sendo considerados excelentes, de acordo com (LANDIS; KOCH, 1977). A acurácia global, para ambos os anos, foi maior que o índice Kappa, logo, foi observado que os resultados de mapeamento foram excelentes.

A matriz confusão foi usada para determinar a exatidão para cada classe de cobertura do solo mapeada, por meio da estimativa dos erros de omissão e inclusão, e a acurácia do produtor e usuário, respectivamente (Tabela 5).

Tabela 5 - Resultados obtidos para as acurácias do produtor e do usuário (em porcentagem) para as 5 classes mapeadas, para os anos de 2020 e 2021.

Classe	2020		2021	
	Acurácia Produtor (%)	Acurácia Usuário (%)	Acurácia Produtor (%)	Acurácia Usuário (%)
Floresta	98,5	94,6	95,7	94,7
Campos	89,8	87,0	91,2	90,5
Corpos d'água	98,2	98,6	98,6	96,6
Área antropizada	87,2	94,4	92,3	93,8
Área Urbana	92,7	91,0	83,9	92,1

Fonte: do autor (2022).

As classes temáticas de Floresta e Corpos d'água apresentaram excelente acurácia, com percentual de exatidão de 98,5 e 98,2, respectivamente, para o ano de 2020, e 97,2 e 98,6, respectivamente, para o ano de 2021. Estes valores, de acurácia do produtor, representam que os polígonos encontrados nessas classes, em campo como Floresta e Corpos d'água estão representados no mapeamento como Floresta e Corpos d'água, ou seja, houve um erro de omissão para estas classes de apenas 1,5% (Floresta) e 1,8% (Corpos d'água) para 2020, e 2,8% (Floresta) e 1,4% (Corpos d'água) para 2021.

Com base na análise dos valores referentes à acurácia do usuário a classe Campos, para ambos os anos, apresentou 13% (2020) e 9,5% (2021) de erro de comissão, ou seja, vários polígonos pertencentes a outras classes foram erroneamente mapeados como Campos, onde a confusão se deu em áreas das classes de Floresta e Área antropizada.

Um fato de significativa importância é que as duas classes de vegetação, Floresta e Campos, apresentaram valores muito bons em termos de acurácia do produtor (98,5% para Floresta e 89,8 para Campos -2020, e 95,7% para Floresta e 91,2% para Campos -2021) e de acurácia do usuário (94,6% para Floresta e 87,0 para Campos - 2020, e 94,7% para Floresta e 90,5% para Campos - 2021), significando baixos erros de comissão e omissão para estas classes.

5 CONSIDERAÇÕES FINAIS

A partir dos resultados obtidos da classificação de cobertura do solo da área do município de Lábrea entre os anos de 2020 e 2021, foi possível observar que a perda de vegetação nativa durante esses anos foi de aproximadamente 518,35 km². As classes consideradas naturais, como Floresta, Campos e Corpos d'água sofreram uma diminuição em suas áreas, e as classes consideradas antropizadas, Área antropizada e Área urbana, tiveram um aumento em sua área, em km².

A utilização dos índices de vegetação se mostrou como sendo de grande utilidade para a classificação, visto que melhorou o desempenho do classificador por acrescentar características nas bandas espectrais além das que já compõe a imagem. O NDVI auxiliou na identificação das áreas que sofreram algum tipo de alteração entre esses anos, o que mostrou ser uma alternativa de avaliação temporal de mudanças entre esses anos diferentes. O NDVI diferença mostrou-se um bom indicador de tendência para regiões com incidências de alteração da vegetação.

O mapeamento realizado pelo algoritmo do *Random Forest* apresentou um resultado eficaz de classificação de cobertura do solo, com uma acurácia global e índice Kappa considerados excelentes, assim como os valores de acurácias do produtor e do usuário. Com uma acurácia global de 93,3% para o ano de 2020 e 95,3% para o ano de 2021, e índices Kappa de 0,91 e 0,94, para 2020 e 2021, respectivamente. Entre as classes avaliadas, as de Floresta e Corpos d'água foram as que apresentaram melhor exatidão, para ambos os anos analisados, significando que os polígonos classificados no mapeamento correspondem a essas classes em campo. A classe de Campos foi a que apresentou mais erros de comissão, com acurácia do usuário de 87,0% para 2020 e 90,5% para 2021, ou seja, vários polígonos foram erroneamente classificados como Campos no mapeamento.

A região amazônica, por sua extensa cobertura vegetal, está sujeita a exploração ilegal, por isso o uso de geotecnologias que auxiliem no monitoramento se tornam de grande importância. Com isso, conclui-se que, em relação à plataforma Google Earth Engine, é uma ferramenta de geotecnologia ágil, com o tempo de processamento extremamente rápido e que permite classificações geradas em um espaço de tempo curto, precisão e de intuitivo manuseio, sendo de grande valia para o fornecimento de dados ambientais, além de ser uma ferramenta de excelente fornecimento de dados para pesquisas e estudos científicos. O acesso aos conteúdos relativos a plataforma, são encontrados com facilidade na internet, o que facilita a sua utilização. Uma das desvantagens do GEE é a taxa de serviços para grandes volumes de dados, o que pode limitar o processamento de análises em áreas grandes e que utilizem uma capacidade de processamento maior da plataforma.

Para trabalhos futuros recomenda-se que para áreas em que ocorram mistura de vegetação, solo exposto e água, como área de urbanização e mineração, se faça uma definição melhor das amostras de treinamento e aperfeiçoamento do algoritmo de classificação. Por ocorrer uma mistura de várias classes, o algoritmo confunde as classes mapeadas.

REFERÊNCIAS BIBLIOGRÁFICAS

- ABOUD NETA, S. R. et al. Multitemporal change detection using the NDVI model in the soil use and land cover. **Anuario do Instituto de Geociencias**, v. 41, n. 3, p. 592–604, 2018.
- AIRES, U. R. V. **Utilização de NDVI para análise de influência da modificação da cobertura vegetal no regime de vazões**. Viçosa: 2018.
- ALMEIDA, A. S. DE; VIEIRA, I. C. G. Conflitos no uso da terra em Áreas de Preservação Permanente em um polo de produção de biodiesel no Estado do Pará. **Revista Ambiente e Agua**, v. 9, n. 3, p. 445–458, 13 ago. 2014.
- ANDRADE, J. B.. **Fotogrametria**. 2. ed. Curitiba: Sbee, 2003. 255 p.
- ANTUNES, A. F. B.; LINGNAU, C. Uso de índices de acurácia para avaliação de mapas temáticos obtidos por meio de classificação digital. **GIS BRASIL**, p. 1–15, 1997.
- BALBINOT, B. L. et al. **Google Drive. Tutorial Programa de Educação Tutorial Sistemas de Informação**. Santa Maria: 2016.
- BECKER, B. K. **Amazônia**. São Paulo: Ática, 1998
- BELGIU, M.; DRĂGU, L. Random forest in remote sensing: A review of applications and future directions. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 114, p. 24–31, 1 abr. 2016.
- BRASIL. Departamento Nacional de Produção Mineral. Projeto RADAMBRASIL. **Levantamento de recursos naturais folhas SB. 20 Purus**. Ed. Fac-similar. vol. 17. Rio de Janeiro. 1978.
- BREIMAN, L. **Random Forests**. 2001.
- BRITO, A. DE. **Acurácia e precisão do mapeamento da flora nativa e dos reflorestamentos de Minas Gerais**. 2008.
- CARVALHO, T. S.; MAGALHÃES, A. S.; DOMINGUES, E. P. Desmatamento e a contribuição econômica da floresta na amazônia. **Estudos Economicos**, v. 46, n. 2, p. 499–531, 1 abr. 2016.
- CASTRO, E. Dinâmica socioeconômica e desmatamento na Amazônia. **Novos Cadernos NAEA**, v. 8, n. 2, p. 5–39, 2005.

CENAMO, M. C.; CARRERO, G. C.; SOARES, P. G. **Redução de Emissões do Desmatamento e Degradação Florestal (REDD+) Estudo de oportunidades para a região Sul do Amazonas**. 2011. Disponível em: <<https://www.researchgate.net/publication/327043278>>.

COELHO, A. L. N. Uso de produtos de sensoriamento remoto para delimitação de área efetivamente inundável: estudo de caso do baixo curso do rio Benevente Anchieta - ES. **Rev. Geogr**, v. 4, p. 53–63, 2010.

COHEN, J. A coefficient of agreement for nominal scales. **Educational and Psychological Measurement**, v. XX, 1960.

COLTIN, B. et al. Automatic boosted flood mapping from satellite data. **International Journal of Remote Sensing**, v. 37, n. 5, p. 993–1015, 3 mar. 2016.

CONGALTON, Russell G. *et al.* **Assessing the Accuracy of Remotely Sensed Data: principles and practices**. 3. ed. Boca Raton: Crc Press, 2019. 346 p.

FEARNSIDE, P. M. **Amazonia and global warming: Annual balance of greenhouse gas emissions from land-use change in Brazil's Amazon region**. Massachusetts: 1996.

FEARNSIDE, P. M.; GRAÇA, P. M. L. DE A. **BR-319: Brazil's Manaus-Porto Velho Highway and the potential impact of linking the Arc of Deforestation to Central Amazonia**. **Environmental Management**, nov. 2006.

FERRARINI, Sebastião Antonio. **Lábrea**. Manaus, Imprensa Oficial, 1980, p. 59.

FERREIRA, L. V.; VENTICINQUE, E.; ALMEIDA, S. O desmatamento na Amazônia e a importância das áreas protegidas. 2005.

FITZ, P. R. **Geoprocessamento sem complicacao**. São Paulo: Oficina de Textos, 2008.

FOODY, G. M. Status of land cover classification accuracy assessment. **Remote Sensing of Environment**, p. 185–201, 21 jun. 2002.

FOODY, G. M. Sample size determination for image classification accuracy assessment and comparison. **International Journal of Remote Sensing**, v. 30, n. 20, p. 5273–5291, 2009.

FRANCO, M. H. M. Novas configurações territoriais no Purus indígena e extrativista. **EDUA**, v. 1, p. 153–166, 2010.

GANEM, K. A. **Classificação da cobertura do solo na caatinga a partir de imagens do Landsat-8 e da ferramenta Google Earth Engine: uma comparação entre dados com e sem correção atmosférica**. Brasília: 2017.

GOLLNOW, F.; LAKES, T. Policy change, land use, and agriculture: The case of soy production and cattle ranching in Brazil, 2001-2012. **Applied Geography**, v. 55, p. 203–211, 1 dez. 2014.

GORELICK, N. et al. Google Earth Engine: Planetary-scale geospatial analysis for everyone. **Remote Sensing of Environment**, v. 202, p. 18–27, 1 dez. 2017.

HANSEN, M. C. et al. High-Resolution Global Maps of 21st-Century Forest Cover Change. **Science**, p. 850–853, 14 maio 2018.

HECHT, S. B. **Environment, Development and Politics: Capital Accumulation and the Livestock Sector in Eastern Amazonia** *World Development*. 1985.

HUANG, H. et al. Mapping major land cover dynamics in Beijing using all Landsat images in Google Earth Engine. **Remote Sensing of Environment**, v. 202, p. 166–176, 1 dez. 2017.

HUSCH, B. *et al.* **Forest Mensuration**. New York: Wiley, 1982. 402 p.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Mapa de Solos do Brasil**. 2005.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Mapa de Solos do Brasil**. 2010.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA – IBGE. **Mapa de Solos do Brasil**. 2021.

JANSSEN, L. L. F.; WEL, F. J. M. VAN DER. Accuracy Assessment of Satellite Derived Land-Use Data: A Review. **Photogrammetric Engineering & Remote Sensing**, v. 60, n. 4, p. 419–426, 4 abr. 1994.

JENSEN, J. R. **Introductory Digital Image Processing**. Englewood Cliffs, Prentice-Hall, New Jersey: 1986.

JUSTICE, C. O. et al. **The Moderate Resolution Imaging Spectroradiometer (MODIS): Land Remote Sensing for Global Change Research** *IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING*. 1998. Disponível em: <<http://eosps0.gsfc.gov>>.

KELLEY, L. C.; EVANS, S. G.; POTTS, M. D. Richer histories for more relevant policies: 42 years of tree cover loss and gain in Southeast Sulawesi, Indonesia. **Global Change Biology**, v. 23, n. 2, p. 830–839, 1 fev. 2017.

LANDIS, J. R.; KOCH, G. G. **The Measurement of Observer Agreement for Categorical Data**. 1977.

LAURANCE, W. F. Mega-development trends in the Amazon implications for global change. p. 113–122, 2000.

LEAN, J. et al. The simulated impact of Amazonian deforestation on climate using measured ABRACOS vegetation characteristics. p. 549–575, 1996.

LOBELL, D. B. et al. A scalable satellite-based crop yield mapper. **Remote Sensing of Environment**, v. 164, p. 324–333, 1 jul. 2015.

LO, C. P.; YEUNG, A. K. W. Concepts and Techniques of Geographic Information Systems. **International Journal of Geographical Information Science**, v. 17, n. 8, p. 819–820, dez. 2003.

LORENZETT, C. D. C.; TELÖCKEN, A. V. **Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forest e J48 na tomada de Decisão**. 2017.

LOURENÇO, R. W.; LANDIM, P. M. B. **Estudo da variabilidade do “Índice de Vegetação por Diferença Normalizada/NDVI” utilizando krigagem indicativa**. 2004.

MAPBIOMAS. **MapBiomias Brasil**. 2022. Disponível em: <https://mapbiomas.org/>

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, 3 maio 2018.

MCFEETERS, S. K. The use of the Normalized Difference Water Index (NDWI) in the delineation of open water features. **International Journal of Remote Sensing**, v. 17, n. 7, p. 1425–1432, 1996.

MEDEIROS, P. R. DE C. **COMPARAÇÃO ENTRE OS DADOS DE USO E COBERTURA DO SOLO DO TERRACLASS E O CENSO AGROPECUÁRIO NO MUNICÍPIO DE LÁBREA - AM**. Rio de Janeiro: Pontifícia Universidade Católica do Rio de Janeiro, 25 abr. 2019.

MERTENS, B. et al. **Crossing spatial analyses and livestock economics to understand deforestation processes in the Brazilian Amazon: the case of S5o Felix do Xingó in South Para**. 2002.

MONICO, J. F. G. et al. Acurácia e precisão: revendo os conceitos de forma acurada. **Boletim de Ciências Geodésicas**, p. 469–483, 3 jul. 2009.

NEPSTAD, D. et al. **Avança Brasil: os custos ambientais para a Amazônia**. 1. ed. ed. Belém: 2000.

NEPSTAD, D. et al. Inhibition of Amazon deforestation and fire by parks and indigenous lands. **Conservation Biology**, v. 20, n. 1, p. 65–73, fev. 2006.

PAULA ASSUMPCÃO CORDEIRO, A. et al. Regiões homogêneas de vegetação utilizando a variabilidade do NDVI. **Ciência Florestal**, v. 27, n. 3, p. 883–896, 2017.

PEKEL, J. F. et al. High-resolution mapping of global surface water and its long-term changes. **Nature**, v. 540, n. 7633, p. 418–422, 15 dez. 2016.

PORTO CHAVES, R.; CUNHA CALLADO, A. A. Análise das relações entre o grau de complexidade das estruturas das cadeias de suprimento e o uso de indicadores de desempenho. **Antônio André Cunha Callado Rev. Ciênc. Admin**, n. 1, p. 80–105, 2014.

PRODES. **PRODES - Amazônia**. 2022. Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>. Acesso em: 25 jul. 2022

RICHARDS, J. A. **Remote Sensing Digital Image Analysis**. [s.l.] Springer International Publishing, 2022.

ROUSE, J. W. et al. **Monitoring The Vernal Advancement And Retrogradation (Green Wave Effect) Of Natural Vegetation**. 1974.

SAWYER, D. 2001. Evolução demográfica, qualidade de vida e Desmatamento na Amazônia. Pages 73-90 in 20 editors. **Causas e dinâmica do desmatamento na Amazônia**. Ministério do Meio Ambiente (MMA), Brasília, D.F., Brazil

SIMEÃO DE MEDEIROS, J. **DESENVOLVIMENTO METODOLÓGICO PARA A DETECÇÃO DE ALTERAÇÕES DA COBERTURA VEGETAL ATRAVÉS DA ANÁLISE DIGITAL DE DADOS MSS LANDSAT**. 1987.

STEFFEN, W. et al. **Global change and the earth system**. 2004.

STEHMAN, S. V. **Practical Implications of Design-Based Sampling Inference for Thematic Map Accuracy Assessment** ENVIRON. 2000.

STEHMAN, S. V.; WICKHAM, J. D. Pixels, blocks of pixels, and polygons: Choosing a spatial unit for thematic accuracy assessment. **Remote Sensing of Environment**, v. 115, n. 12, p. 3044–3055, 15 dez. 2011.

STORY, M.; CONGALTON, R. G. Accuracy Assessment: A User's Perspective. **Remote Sensing Brief**, p. 397–399, 1986.

TAURION, C. **Cloud Computing: computação em nuvem: transformando o mundo da tecnologia da informação**. Rio de Janeiro: Ed. Brasport, 2009.

VALE, J. R. B. **Análise da dinâmica do uso e cobertura da Terra nas áreas desflorestadas do estado do Pará por meio da plataforma Google Earth Engine**. Belém: 2019.

WATZLAWICK, L. F. **Estimativa de biomassa e carbono em floresta ombrófila mista e plantações florestais a partir de dados de imagens de satélite IKONOS II**. Curitiba: Universidade Federal do Paraná, 5 set. 2003.

XU, H. Modification of normalised difference water index (NDWI) to enhance open water features in remotely sensed imagery. **International Journal of Remote Sensing**, v. 27, n. 14, p. 3025–3033, 20 jul. 2006.

ZHANG, Q. et al. Building a better Urban picture: Combining day and night remote sensing imagery. **Remote Sensing**, v. 7, n. 9, p. 11887–11913, 2015.