



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

**MAPEAMENTO DA AGRICULTURA DE PEQUENA ESCALA E  
DOS SISTEMAS AGROFLORESTAIS COM TÉCNICAS DE  
APRENDIZADO DE MÁQUINA NA REGIÃO DO BAIXO  
TOCANTINS, PA.**

Marcus Vinicius Gonçalves da Silva

Relatório final de Iniciação Científica,  
orientado pela Dra. Maria Isabel Sobral  
Escada e coorientada pela Dra. Anielli  
Rosane Souza.



MINISTÉRIO DA CIÊNCIA, TECNOLOGIA, INOVAÇÕES E COMUNICAÇÕES  
**INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS**

**MAPEAMENTO DA AGRICULTURA DE PEQUENA ESCALA E  
DOS SISTEMAS AGROFLORESTAIS COM TÉCNICAS DE  
APRENDIZADO DE MÁQUINA NA REGIÃO DO BAIXO  
TOCANTINS, PA.**

Marcus Vinicius Gonçalves da Silva

Relatório final de Iniciação Científica,  
orientado pela Dra. Maria Isabel Sobral  
Escada e coorientada pela Dra. Anielli  
Rosane Souza.

## RESUMO

Metodologias para o mapeamento do uso e cobertura da terra têm sido desenvolvidas para a classificação de grandes extensões territoriais, como as do bioma Amazônia. Esses mapeamentos priorizam a identificação de classes de uso e cobertura da terra que são mais facilmente identificáveis em imagens de satélite, ignorando algumas classes como a Agricultura de Pequena Escala (AGPE) ou sistemas extrativistas. A falta de informações geoespaciais da AGPE resulta no desconhecimento das economias associadas à ela, aumentando sua invisibilidade. É importante destacar que os sistemas agrícolas camponeses desempenham papel crucial na economia regional e na provisão de alimentos para a população local. A variação espacial e espectral da AGPE traz complexidade em seu mapeamento, resultando em omissões e/ou imprecisões em sua representação espacial. Este trabalho tem como objetivo estabelecer uma matriz metodológica para a classificação do uso e cobertura da terra, especialmente para AGPE para os municípios de Abaetetuba, Igarapé-Miri, Cametá, Mocajuba e Baião, localizados na região nordeste do estado do Pará, considerando o ano de 2017. Para isso foi utilizado um cubo de dados de imagens do MSI/Sentinel-2 e testados diferentes algoritmos de classificação em uma área piloto, tais como, Random Forest (RFOR); Support Vector Machine (SVM); Temporal Convolutional Neural Network (TEMPCNN); Lightweight Temporal Self-Attention Encoder (LTAE), implementados no pacote Sits (Satellite Image Time Series Analysis on Earth Observation Data Cubes). O cubo de dados foi construído com imagens mensais para o período de 1º de janeiro de 2017 a 31 de dezembro de 2017, considerando as bandas B02, B03, B04, B05, B06, B07, B08, B08A, B11, B12, e os índices espectrais NDVI, NBR e as frações solo, sombra e vegetação, obtidas com Modelo Linear de Mistura Espectral (MLME). Os algoritmos foram treinados com o mesmo conjunto de amostras. Foram coletadas 1.753 amostras representadas por pixels, distribuídas em 10 classes, sendo elas: agricultura de pequena escala, agricultura de larga escala, pasto limpo, pasto sujo, vegetação secundária inicial, vegetação secundária avançada, área urbana, outros, água e piscicultura. Foi estimada a acurácia global dos algoritmos testados, para a área piloto, com 1.168 amostras (pixels), obtendo-se índices de acurácia global de 81,33%, 76,78%, 79,45% e 70,37%, para os algoritmos RFOR, SVM, LTAE e TEMPCNN, respectivamente. A abordagem metodológica desenvolvida demonstrou a importância do uso de cubos de imagens do MSI/Sentinel-2A e a viabilidade do uso de métodos semiautomáticos para a classificação da AGPE, apresentando altos índices de acurácia, com importante destaque para a inclusão de atributos temporais na classificação. Devido aos altos índices de acurácia obtidos, o algoritmo RFOR foi escolhido para o mapeamento da área de estudo como um todo. O mapeamento revela que a classe AGPE abrange 9.709 ha, a classe VSI ocupa 96.734 ha, enquanto a classe VSA se estende por 260.276 ha. Essas classes, em grande parte associadas à AGPE, destacam a relevância da agricultura camponesa na região, reforçando a importância do seu monitoramento. A inserção dessa classe, bem como sua diferenciação em relação à agricultura de larga escala, representa um primeiro passo na elaboração de políticas mais adequadas às categorias agrícolas camponesas que apresentam especificidades e a elaboração de políticas diferenciadas para seu fortalecimento e sustentação no longo prazo.

## ABSTRACT

Methodologies for land use and land cover mapping have been developed for the classification of large territorial areas, such as the Amazon biome. These mappings prioritize the identification of land use and land cover classes that are more easily identifiable in satellite images, often overlooking certain classes like Small-Scale Agriculture (AGPE) or extractive systems. The lack of geospatial information on AGPE results in a lack of knowledge about the economies associated with it, increasing its invisibility. It is important to emphasize that peasant agricultural systems play a crucial role in the regional economy and in providing food for the local population. The spatial and spectral variation of AGPE adds complexity to its mapping, leading to omissions and/or inaccuracies in its spatial representation. This study aims to establish a methodological framework for land use and land cover classification, particularly for AGPE, in the municipalities of Abaetetuba, Igarapé-Miri, Cametá, Mocajuba, and Baião, located in the northeastern region of the state of Pará, considering the year 2017. For this purpose, a data cube of MSI/Sentinel-2 images was used, and different classification algorithms were tested in a test area, such as Random Forest (RFOR), Support Vector Machine (SVM), Temporal Convolutional Neural Network (TEMPCNN), and Lightweight Temporal Self-Attention Encoder (LTAE), implemented in the Sits package (Satellite Image Time Series Analysis on Earth Observation Data Cubes). The data cube was built with monthly images from January 1, 2017, to December 31, 2017, considering bands B02, B03, B04, B05, B06, B07, B08, B08A, B11, B12, and spectral indices NDVI, NBR, and soil, shadow, and vegetation endmembers obtained with the Linear Spectral Mixture Model (MLME). The algorithms were trained with the same set of samples. A total of 1,753 samples represented by pixels were collected, distributed across 10 classes: small-scale agriculture, large-scale agriculture, clean pasture, dirty pasture, initial secondary vegetation, advanced secondary vegetation, urban area, others, water, and fish farming. The overall accuracy of the tested algorithms was estimated for the test area with 1,168 samples (pixels), yielding global accuracy indices of 81.33%, 76.78%, 79.45%, and 70.37% for the RFOR, SVM, LTAE, and TEMP CNN algorithms, respectively. The developed methodological approach demonstrated the importance of using MSI/Sentinel-2A image cubes and the feasibility of using semi-automated methods for AGPE classification, showing high accuracy levels, with a significant emphasis on the inclusion of temporal attributes in the classification. Due to the high accuracy rates obtained, the RFOR algorithm was chosen for mapping the entire study area. The mapping results reveal that the AGPE class corresponds to 9,709 ha, the initial secondary vegetation class to 96,734 ha, while the advanced secondary vegetation class corresponds to 260,276 ha. These classes, largely associated with AGPE, highlight the relevance of peasant agriculture in the region, reinforcing the importance of its monitoring. The inclusion of this class, as well as its distinction from large-scale agriculture, represents a first step towards the development of more appropriate policies for peasant agricultural categories, which have specific characteristics, and the creation of differentiated policies for their long-term strengthening and maintenance.



## LISTA DE FIGURAS

	<b><u>Pág.</u></b>
<b>Figura 2.1</b> – Área de estudo .....	4
<b>Figura 2.2</b> - Produção de Açaí plantado nos municípios do baixo Tocantins no ano de 2017.....	5
<b>Figura 2.3</b> - Área colhida de açaí nos municípios do baixo Tocantins em 2017.....	6
<b>Figura 2.4</b> - Número de efetivo bovino para o ano de 2017 no baixo Tocantins.....	6
<b>Figura 2.5</b> – Área piloto.....	8
<b>Figura 2.6</b> - Bandas espectrais do Sentinel-2A/B utilizadas.....	9
<b>Figura 2.7</b> – Número de amostra de treinamento por classe.....	15
<b>Figura 3.1</b> - Classificação da área piloto .....	18
<b>Figura 3.2</b> - Matriz de confusão RFOR .....	19
<b>Figura 3.3</b> – Matriz de confusão SVM .....	19
<b>Figura 3.4</b> – Matriz de confusão LTAE .....	20
<b>Figura 3.5</b> – Matriz de Confusão TempCNN .....	21
<b>Figura 3.6</b> - Mapa de uso e cobertura da terra .....	26
<b>Figura 3.7</b> - Área de cada classe.....	26



## LISTA DE TABELAS

	<b><u>Pág.</u></b>
<b>Tabela 2.1</b> - Materiais .....	7
<b>Tabela 2.2</b> - Chave de interpretação .....	11
<b>Tabela 3.1</b> - Comparação geral dos classificadores .....	23
<b>Tabela 3.2</b> - Comparação por classe de interesse dos classificadores .....	23
<b>Tabela 3.3</b> - Área das classes de uso e cobertura da terra mapeadas com o RFOR para o ano de 2017 .....	25





# SUMÁRIO

	<u>Pág.</u>
<b>1. INTRODUÇÃO.....</b>	<b>1</b>
1.1 Objetivo Geral.....	3
1.2 Objetivos específicos.....	3
<b>2. METODOLOGIA.....</b>	<b>3</b>
2.1 Materiais e Métodos.....	4
2.1.1 Área de estudo.....	4
2.1.2 Materiais.....	7
2.2 Métodos.....	8
2.2.1 Geração de cubo de dados.....	8
2.2.2 Elaboração de uma chave de interpretação.....	11
2.2.3 Coleta de amostras de treinamento.....	14
2.2.4 Classificação.....	15
2.2.5 Avaliação da classificação.....	17
<b>3. RESULTADOS E DISCUSSÃO.....</b>	<b>18</b>
3.1 Resultados da Classificação e Avaliação de Acurácia.....	18
3.2 Análise do uso e cobertura da terra da Região do Baixo Tocantins em 2017.....	25
<b>4. CONCLUSÃO.....</b>	<b>27</b>
<b>5. BIBLIOGRAFIA.....</b>	<b>29</b>

## 1. INTRODUÇÃO

A relação entre ecossistema e economia se faz presente em diversas áreas do sistema de produção agrícola global, sendo muitas vezes vista de maneira antagônica e excludente, em uma perspectiva em que os sistemas econômicos e a conservação dos recursos naturais, não podem coexistir. Porém, na Amazônia, essa relação deve ser vista de outra forma, já que muitas atividades econômicas são desenvolvidas a partir dos recursos naturais presentes na região, que devem se manter preservados ou apresentar poucas alterações, para que seja possível desenvolver a produção agrícola, como o roçado, bem como as atividades agroflorestais e extrativistas, fornecendo condições para a geração de renda para a população encontrada na região (COSTA et. al. 2022). Sendo assim, faz-se necessário ampliar a compreensão do uso e cobertura da terra da região para melhor compreender as dinâmicas locais das atividades econômicas que afetam a utilização dos recursos naturais. Uma das atividades de grande impacto socioeconômico desenvolvida na Amazônia é a agricultura camponesa, com destaque para a região do Baixo Tocantins, localizada no nordeste do estado do Pará, Brasil (COSTA, 2021). A agricultura camponesa nessa região desempenha um papel crucial na economia local e na provisão de alimentos de muitas famílias, por meio da produção de farinha, cacau, pimenta e açaí, entre outros produtos. Essa forma de agricultura é caracterizada por áreas de produção de média e pequena escala, geralmente administradas por famílias que utilizam técnicas tradicionais de cultivo que configuram-se em práticas sustentáveis de manejo da cobertura da terra, mantendo em grande parte, uma relação harmoniosa com a natureza (COSTA, 2012; NOGUEIRA, 2015; CUNHA 2023).

O cultivo do açaí é uma das atividades extrativistas e agrícolas mais importantes na região do Baixo Tocantins. Esse fruto nativo da Amazônia é valorizado por suas propriedades nutritivas e sabor distinto. A colheita e seleção do fruto do açaí se dá de forma manual quando os frutos estão maduros. Após a colheita, o fruto é processado para extração da polpa, que pode ser consumida diretamente ou transformada em diversos produtos como sucos, sorvetes e cremes.

O cultivo do açaí não só gera renda para as famílias camponesas que manejam e coletam o fruto, mas também desempenha um papel vital na preservação da cultura local e da biodiversidade da região (CHAVES et al., 2015), em especial, quando o

manejo é feito de forma pouco intensiva, sem a substituição de árvores ou de outras palmeiras pela palmeira do açaí.

A produção camponesa de pequena escala desempenha um papel importante tanto socioeconômico quanto ambiental na Amazônia, gerando uma economia significativa conforme indicado por Costa (2016). Essas atividades agrícolas causam impactos ambientais menores, com menos desmatamento, uma vez que a floresta deve permanecer viva, com nenhuma ou pouca emissão de carbono, quando comparadas às atividades agropecuárias de grande escala (COSTA, 2016).

Os sistemas de monitoramento do uso e cobertura da terra da Amazônia, historicamente realizados com imagens dos sensores a bordo do satélite Landsat, com resolução espacial de 30 metros, tendem a priorizar o mapeamento de classes de uso e cobertura da terra, como a agricultura de larga escala e pastagem, que são mais facilmente detectáveis nessas imagens, por ocorrerem em áreas mais amplas. Como consequência, as economias de larga escala e suas dinâmicas são melhor representadas do que as economias ligadas à produção camponesa, aumentando sua invisibilidade para os formuladores de políticas públicas.

Reconhecendo a importância dessas economias e de sua representação cartográfica, diversos estudos têm sido conduzidos por pesquisadores do Laboratório de Investigação de Sistemas Socioambientais(LiSS) (SOUZA et al., 2019; SANTOS et al., 2020; PORTO et al., 2020). Esses estudos têm, em sua maioria, o objetivo de desenvolver metodologias para o mapeamento e caracterização do uso e cobertura da terra, com ênfase na cartografia de classes associadas à produção camponesa, como a agricultura de pequena escala, vegetação secundária e sistemas agroflorestais na Amazônia. O mapeamento da vegetação secundária é particularmente relevante para este trabalho devido à sua ligação com a agricultura de pequena escala (sistema de roçado ou cultivo itinerante), que utiliza o sistema de pousio para recuperação da fertilidade dos solos, podendo durar de 4 a 18 anos ou mais (BOSERUP, 2013; JAKOVAC et al., 2015).

Para suprir essa demanda e complementar a base de dados de uso e cobertura da terra do LiSS, este trabalho propõe a realização do mapeamento do uso e cobertura da terra nos municípios de Abaetetuba, Igarapé-Miri, Cametá, Mocajuba e Baião, para o ano de

2017. Este ano foi selecionado por corresponder ao período em que foi realizado o censo agropecuário do IBGE, cujos dados dão subsídios aos resultados das classificações e complementam a caracterização das atividades de uso e cobertura da terra mapeadas. A caracterização dessas atividades será feita com base em variáveis relacionadas aos sistemas de produção existentes na área de estudo.

### **1.1 Objetivo Geral**

Dado que uma parcela significativa da população Amazônica depende da economia da camponesa, em que está associada à produção de pequena escala e extrativista, e considerando que as classes de uso e cobertura da terra, associadas a essas atividades, não têm sido devidamente monitoradas, o desenvolvimento de um método para este mapeamento é de grande importância, particularmente para a região do Baixo Tocantins, situada no Nordeste do Pará, em que grande parte dos estudos do LSS tem sido realizado. Nesse sentido, o objetivo deste trabalho é desenvolver metodologias para o mapeamento e caracterização do uso e cobertura da terra, dando ênfase às classes de agricultura de pequena escala e vegetação secundária na Amazônia.

### **1.2 Objetivos específicos**

Considerado objetivo geral foram definidos 3 (três) objetivos específicos:

- a) Estabelecer um método de classificação que melhor identifique e caracterize os usos e coberturas da terra da região do Baixo Tocantins, especialmente as classes vegetação secundária inicial, vegetação secundária avançada e agricultura anual de pequena escala para o ano de 2017 em experimento em uma área piloto;
- b) Avaliação de algoritmos de aprendizado de máquina testados na classificação de uso e cobertura da terra em imagens Sentinel do cubo de dados (Brazil Data Cube);
- c) Geração, análise e avaliação do mapa de uso e cobertura da terra, contendo as classes vegetação secundária inicial, vegetação secundária avançada, agricultura anual de pequena escala baseado no açaí de várzea e terra firme para área de estudo;

## **2. METODOLOGIA**

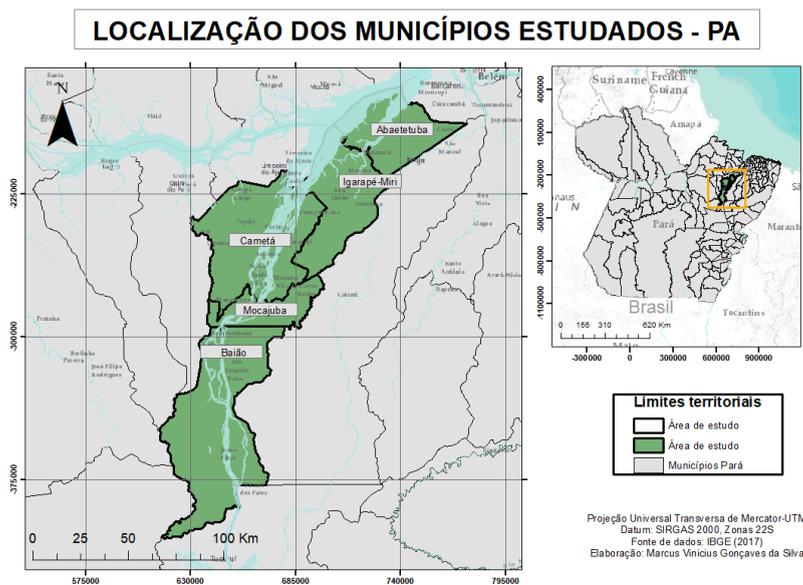
Esta seção apresenta os materiais e os métodos utilizados para o desenvolvimento deste trabalho, tendo como destaque o mapeamento das classes de vegetação secundária inicial, vegetação secundária avançada e agricultura anual de pequena escala.

## 2.1 Materiais e Métodos

### 2.1.1 Área de estudo

A área de estudo, representada abaixo na Figura 2.1, compreende 5 (cinco) município, situados na região nordeste do estado do Pará, conhecida como baixo Tocantins, sendo eles: Cametá, Mocajuba, Baião, Igarapé-Miri e Abaetetuba. A área de estudo está compreendida nos tiles do Sentinel-2A: 22MFC, 22MFB, 22MGC, 22MGD.

Figura 2.1 – Área de estudo

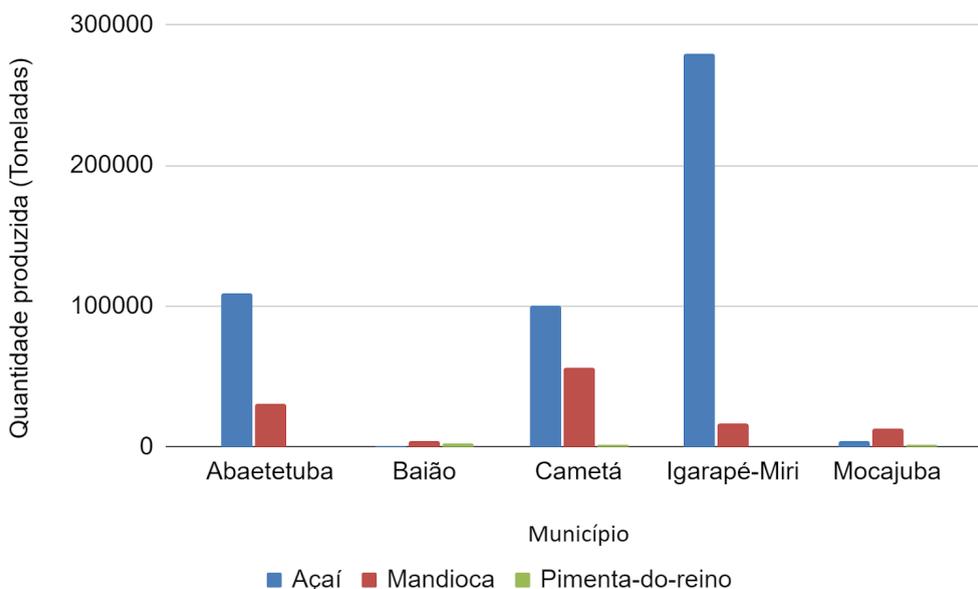


Fonte: Produção do autor (2023)

A produção do açaí pode ocorrer de duas formas, a partir do cultivo ou pela extração do fruto em áreas de ocorrência de palmeiras de açaí em ilhas e/ou várzeas, em áreas alagáveis. Essa produção abrange o beneficiamento e a comercialização do produto, como a produção de polpa ou do açaí *in natura* que é vendido para outras regiões do Brasil e até mesmo para o exterior. A comercialização do açaí desempenha um papel crucial na economia da região, especialmente notável no caso das famílias da Ilha das Onças, na região Metropolitana de Belém. Estas famílias conseguem uma renda mensal

significativa, estimada em cerca de R\$1.500 por família, através da venda deste produto (RODRIGUES, 2019). O Açaí possui uma importância social e cultural significativa para as comunidades locais (TAVARES et al, 2015). Na Figura 2.2 podemos observar a produção do açaí plantado em terra firme no ano de 2017, por meio de variedades desenvolvidas pela EMBRAPA na área de estudo.

Figura 2.2 - Produção de Açaí plantado nos municípios do baixo Tocantins no ano de 2017

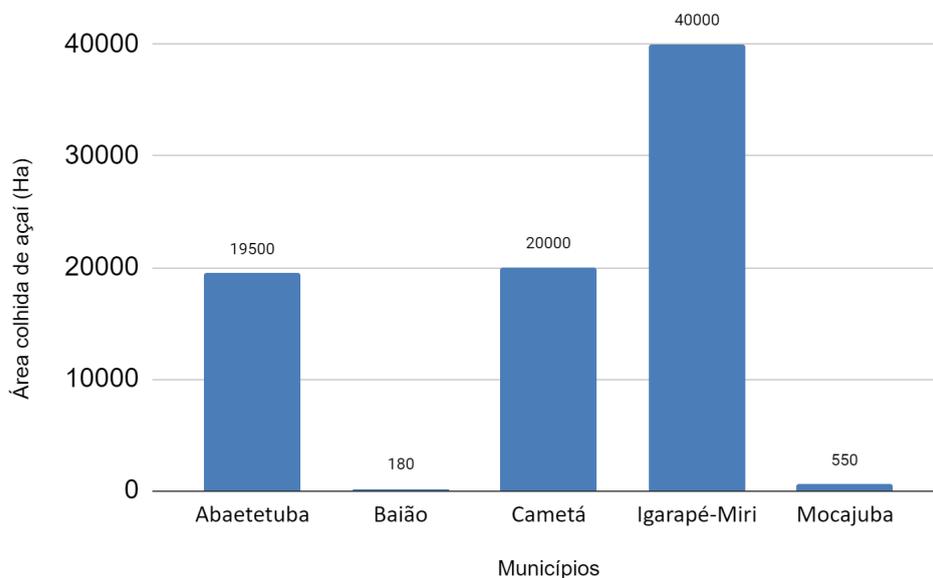


Fonte: IBGE- Produção Agrícola Municipal (2017) - PAM.

Apesar da diferença no tamanho dos municípios, o que tem implicações nas análises das produções municipais aqui apresentadas, alguns elementos podem ser destacados a partir dos dados da Produção Agrícola Municipal (PAM). Na Figura 2.2, observa-se a expressiva produção do açaí, principalmente no município de Igarapé-Miri, com valores aproximados de 40.000 toneladas e em Abaetetuba, juntamente com Cametá, que juntos produziram cerca de 20.000 toneladas. Apesar de não ser tão expressiva como o açaí, a produção agrícola na região é de grande importância para a economia, destacando-se o cultivo da mandioca, com Cametá com mais de 50.000 toneladas, e da pimenta-do-reino, especialmente nos municípios Baião e Mocajuba com valores próximos de 5.000 toneladas, respectivamente.

Na Figura 2.3 são apresentados os valores da produção do açaí extrativo que se concentra nos municípios de Igarapé-Miri, seguido de Cametá, Abaetetuba, Mocajuba e Baião.

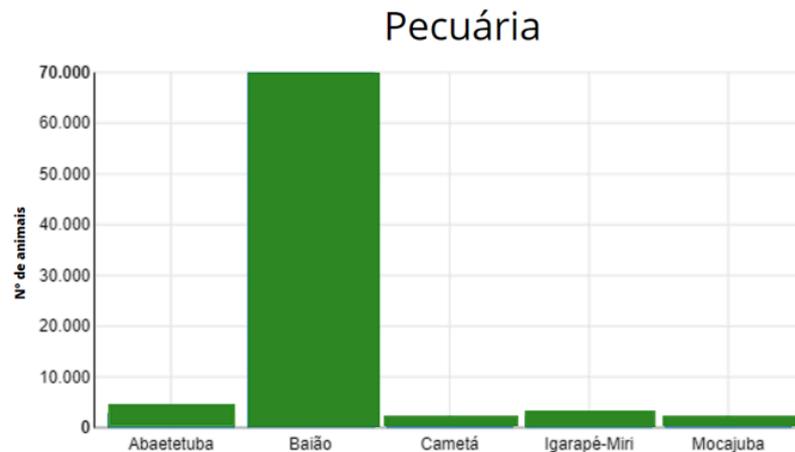
Figura 2.3 - Área colhida de açaí nos municípios do baixo Tocantins em 2017



Fonte: IBGE- Produção da extração vegetal e da silvicultura (2017).

A pecuária é uma atividade importante na Amazônia, (Figura 2.4) impactando de maneira expressiva a floresta e os locais onde essa atividade é exercida. Desse modo, destaca-se o município de Baião, onde se observa um alto número de efetivo de bovinos na região, chegando a 70.000 mil animais no ano de 2017. Nos outros municípios essa atividade apresenta menor importância.

Figura 2.4- Número de efetivo bovino para o ano de 2017 no baixo Tocantins.



Fonte: IBGE- Pesquisa da Pecuária Municipal- PPM (2017).

### 2.1.2 Materiais

Foram utilizados diferentes dados derivados do sensoriamento remoto. Estes dados estão descritos na tabela 2.1:

Tabela 2.1 - Materiais

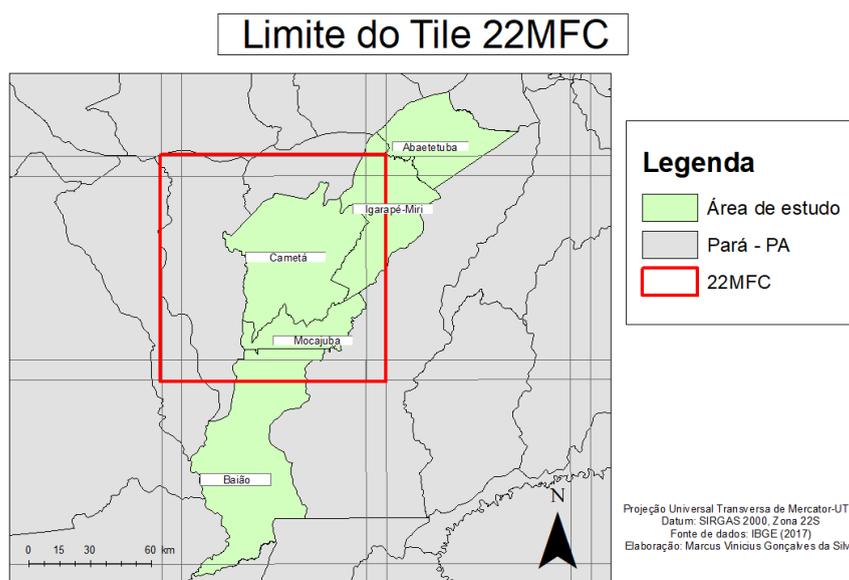
<b>Tipos de dados</b>	<b>Dados</b>	<b>Ano</b>	<b>Fonte</b>
<b>Sensoriamento Remoto</b>	Imagens do Sentinel-2A/B Tiles: 22MFC, 22MFB, 22MGC, 22MGD	2017	Microsoft Planetary Computer (2022)
	Imagens do Google Earth	2017	Distribuída pela Agência espacial Francesa Centre National d'Études Spatiales- CNES (2021)
<b>Temáticos</b>	Máscara de Floresta e Não-floresta	2017	INPE (2017)
<b>Cartográficos</b>	Limites municipais  Limites estaduais		IBGE (2022)

Fonte: Produção do autor (2023)

## 2.2 Métodos

A abordagem metodológica utilizada para o mapeamento do uso e cobertura da terra da região do baixo Tocantins está organizada em 5 etapas. Essas etapas foram realizadas inicialmente em r para uma área piloto que compreende o tile 22MFC do Sentinel-2A, que incorpora grande parte da área de estudo, como podemos observar na Figura 2.5. Em seguida, o mapeamento foi ampliado para a totalidade da área de estudo. Para os processamentos foram utilizados: o sistema de informação geográfica (SIG) QGis (Versão 3.26.) e software livre R por meio do pacote SITS (*Satellite Image Time Series Analysis on Earth Observation Data Cubes*)(CÂMARA et al., 2024).

Figura 2.5 – Área piloto



Fonte: Produção do autor (2023)

### 2.2.1 Geração de cubo de dados

Antes de iniciar a coleta de amostra foi criado um banco de dados no Qgis com dados geográficas da área de estudo como dados de desmatamento, áreas de floresta e de não-floresta, derivados do PRODES do ano de 2017 (INPE, 2017), juntamente com dados do IBGE (shapefiles dos limites municipais e do estado do Pará - 2022), além de imagens do Sentinel-2A/B. Uma das etapas iniciais do processamento de imagens

consistiu em gerar e regularizar o cubo de dados com imagens do Sentinel-2A, que foram adquiridas em intervalos de 16 dias. Esse processo foi realizado no ambiente SITS (*Satellite Image Time Series Analysis on Earth Observation Data Cubes*)(CÂMARA et al., 2024), utilizando a linguagem R. O cubo de dados foi gerado considerando os seguintes parâmetros.

a) Período: 01-01-2017 até 31-12-2017

b) Intervalo: 16 dias

Na geração do cubo de dados as imagens são obtidas para todos os tiles que abrangem a área de estudo, embora inicialmente tenha sido utilizado somente o tile 22 MFC para os experimentos em área piloto. Utilizou-se todas as bandas espectrais do Sentinel-2A, sendo elas: B02, B03, B04, B05, B06, B07, B08, B08A, B11, B12. Essas bandas são comumente utilizadas nos mapeamentos de uso e cobertura da terra, mostrando bons resultados em relação aos estudos de vegetação (QUARTAROLI et al., 2014; SOTHE et al., 2017; BAYLE et al., 2019). Podemos ver na Figura 2.6 as bandas e os seus respectivos comprimentos de ondas e nomes nas imagens do Sentinel-2A.

Figura 2.6 - Bandas espectrais do Sentinel-2A/B utilizadas .

Resolução	Nr da Banda	Nome da Banda	Comprimento de Onda Central (nanômetro)	Combinações de Bandas
10 m	B02	Blue (Azul)	490	Cor Verdadeira RGB 04/03/02 Falsa Cor 1 e 2 RGB 08/04/03 e 04/08/03
	B03	Green (Verde)	560	
	B04	Red (Vermelho)	665	
	B08	NIR (Infravermelho Próximo)	842	
20 m	B05	Red Edge 1	705	SWIR 1 RGB 12/11/8A
	B06	Red Edge 2	740	
	B07	Red Edge 3	783	
	B08A	Red Edge 4	865	
	B11	SWIR 1	1610	
	B12	SWIR 2	2190	

Fonte: Engesat – Soluções em imagens de satélites e geoprocessamento (2015).

A partir das bandas, foram calculados os seguintes índices espectrais:

- a) NDVI (Índice de Vegetação da Diferença Normalizada): O NDVI é utilizado para avaliar e monitorar as condições da vegetação, o qual é calculado a partir da diferença entre a banda do infravermelho próximo (NIR) e da banda do vermelho (RED), (ROUSE et al. , 1973). O índice é expresso pela equação:

$$NDVI = \frac{NIR - RED}{NIR + RED} \quad (3.1)$$

- b) NBR (Índice de Queimada Normalizada): O NBR (Normalized Burn Ratio) é utilizado para avaliar e identificar áreas queimadas, o qual é calculado a partir da diferença entre as bandas do infravermelho próximo (NIR) e do infravermelho médio (SWIR) (KOUTSIAS et al., 1998; FILIPPONI, 2018). Esse índice pode ser importante para identificar as áreas de agriculturas de pequena escala, uma vez que esse tipo de agricultura utiliza o sistema de corte-queima para limpeza da área a ser cultivada. O índice é expresso pela equação:

$$NBR = \frac{NIR - SWIR}{NIR + SWIR} \quad (3.2)$$

- c) MLME (Modelo Linear de Mistura espectral): O MLME é um modelo que permite gerar frações de imagens relativas à composição espectral de um pixel. Considerando que em um pixel pode ocorrer uma mistura de diferentes materiais, como vegetação, solo e sombra, esse modelo parte do princípio de que a reflectância observada em um pixel de uma imagem de satélite pode ser expressa como uma combinação linear das reflectâncias dos componentes puros, conhecidos como "*endmembers*", que estão presentes nesse pixel. Esse índice opera com base em *endmembers*, que são valores de referência obtidos a partir de pixels puros na imagem de satélite, representando solo, vegetação e sombra (SHIMABUKURO et al., 1998).

## 2.2.2 Elaboração de uma chave de interpretação

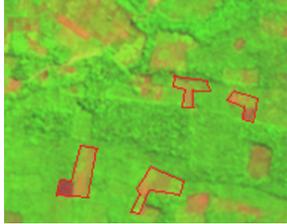
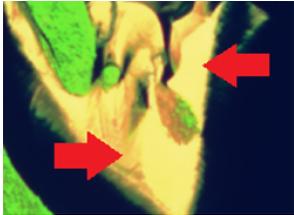
Para construção de uma chave de interpretação foi elaborado um banco de dados no QGIS contendo imagens do Sentinel-2, acessadas com o *plugin* SentinelHub no QGIS, áreas de floresta e de não-floresta (*NÃO-FLO*) derivados do PRODES do ano de 2017. A elaboração da chave de interpretação foi realizada por meio de análise detalhada das imagens, que integrou conhecimentos especializados em interpretação de imagens e informações regionais adquiridas por meio de expedições de campo na área estudada (SOUZA et al., 2021). Esta interpretação visual baseou-se nos seguintes elementos de fotointerpretação: forma, textura, tonalidade e tamanho. Esses elementos foram observados nas imagens do Sentinel-2, composição de banda (R) 11, (G) 8, (B) 2. Durante esse processo foram identificadas as seguintes classes: Agricultura de Larga Escala (AGLE), Agricultura de Pequena Escala (AGPE), Pasto Limpo (PL), Pasto Sujo ou com regeneração (PS), Vegetação Secundária Avançada (VSA), Vegetação Secundária Inicial (VSI), Área Urbana (URB), Outros (OT), Água (AGUA) e Piscicultura (PSI), as quais estão descritas na Tabela 2.2.

Tabela 2.2 - Chave de interpretação das classes de uso e cobertura da terra

Classe	Característica	Descrição	Imagem Sentinel Composição 11(R) 8(G) 2(B)
Agricultura de Larga Escala (AGLE)	Áreas de plantio são formadas por grandes talhões, associados à produção em larga escala com diferentes tipos de cultivo, especialmente açaí, dendê e pimenta-do-reino que pode ocorrer em consórcio com açaí e cacau.	Forma: Regular (maior que 100 ha). Bordas: bem definidas Tonalidade nas bandas 11(R), 8(G) e 2 (B): Laranja a verde limão. Textura: Lisa Contexto: Localizadas em áreas de grandes fazendas.	

Continua

Tabela 2.2 - Continuação

<p>Agricultura de pequena escala (AGPE)</p>	<p>Áreas de plantio são formadas por pequenos talhões associados à produção camponesa com cultivos de mandioca, pimenta-do-reino e açaí.</p>	<p>Forma: regular Bordas: Bem definidas Tamanho: Áreas pequenas (menor que 2 ha). Tonalidade nas bandas 11(R), 8(G) e 2 (B) : Laranja Textura: Lisa. Contexto: Áreas próximas de vegetação secundária em vários estágios</p>	
<p>Água (AGUA)</p>	<p>Representa rios, lagos e lagoas.</p>	<p>Forma: Sinuosa. Borda: Irregulares Tamanho: Variável Tonalidade nas bandas 11(R), 8(G) e 2 (B): Azul escuro. Textura: Lisa. Contexto: Corpos d'água</p>	
<p>Outros (OT)</p>	<p>Representa principalmente por banco de areia ao longo do curso do rio Tocantins e feições com característica de área ou afloramento rochoso.</p>	<p>Forma: Variadas Borda: Irregular Tamanho: Liso Tonalidade nas bandas 11(R), 8(G) e 2 (B): Amarelado Textura: Irregular Contexto: Representada por banco de areias às margens dos rios</p>	
<p>Pasto limpo (PL)</p>	<p>Nesse tipo de pastagem predominam a vegetação herbácea podendo ter ou arbustos baixos. Além disso, pode apresentar leiras que indicam a limpeza e formação de pastagem.</p>	<p>Forma: Variadas. Borda: Bem definidas Tamanho: Variável Tonalidade nas bandas 11(R), 8(G) e 2 (B): Magenta Textura: Lisa ou pouco ondulada Contexto: Ilustra a retirada da cobertura da vegetação com a exposição do solo.</p>	

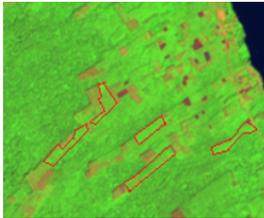
Continua

Tabela 2.2 - Continuação

<p>Pasto sujo e com regeneração (PS)</p>	<p>Pasto sujo é representado por vegetação herbácea e arbustiva. Já a passagem com regeneração refere-se às áreas em que a vegetação nativa se encontra em estágio de regeneração com a presença de vegetação arbustiva e arbórea.</p>	<p>Forma: Variadas                  Borda: Bem definidas                  Tamanho: Variável                  Tonalidade nas bandas 11(R), 8(G) e 2 (B): Magenta com áreas em verde                  Textura: Pouco rugoso                  Contexto: Representado por áreas onde está ocorrendo o crescimento de vegetações rasteiras e de pequeno porte.</p>	
<p>Área urbana (URB)</p>	<p>Manchas urbanas, podendo estar associadas às cidades, vilas, vilarejos e comunidades.</p>	<p>Forma: Irregular.                  Borda: Bem definida.                  Tamanho: Irregular                  Tonalidade nas bandas 11(R), 8(G) e 2 (B): Magenta, tons rosados ou branco                  Textura: Irregular                  Contexto: Representa as cidades, telhados e ruas.</p>	
<p>Vegetação secundária avançada (VSA)</p>	<p>Vegetação que não é caracterizada como primária, já foi cortada. Todavia, apresenta um alto índice de espécies arbóreas e alta densidade vegetal.</p>	<p>Forma: Irregular                  Borda: Irregular                  Tamanho: Normalmente marcadas por grandes extensões                  Tonalidade nas bandas 11(R), 8(G) e 2 (B): Verde escuro                  Textura: Rugoso                  Contexto: Floresta que apresentam fisionomia semelhante às condições naturais iniciais</p>	

Continua

Tabela 2.2 - Continuação

<p>Vegetação secundária inicial (VSI)</p>	<p>Vegetação que não é caracterizada como a de origem do local, apresentando vegetação rasteira com espécies gramíneas e arbustivas em sua maioria.</p>	<p>Forma: Irregular.                  Borda: Bem definidas                  Tamanho: Pequenas e fragmentadas                  Tonalidade nas bandas 11(R), 8(G) e 2 (B): Verde limão                  Textura: Lisa                  Contexto: Locais próximos a atividades humanas onde a vegetação está em processo de regeneração inicial</p>	
<p>Piscicultura (PSI)</p>	<p>Representam tanques artificiais para a piscicultura.</p>	<p>Forma: Regular.                  Borda: Bem definidas                  Tamanho: Menor que 1 ha                  Tonalidade nas bandas 11(R), 8(G) e 2 (B): Azul e roxo                  Textura: Liso                  Contexto: Tanques de criação de peixes</p>	

Fonte: Produção do autor (2024)

### 2.2.3 Coleta de amostras de treinamento

A amostragem foi feita por meio da coleta de pixels, com o objetivo de manter a distribuição equilibrada de amostras entre as diferentes classes presentes na área de estudo. Foram coletadas 1.753 amostras (pixels) em toda a área de estudo, garantindo que as variações que ocorrem dentro de uma mesma classe fossem capturadas. Isso foi importante porque a região tem diferenças em suas características, de forma que as amostras devem representar a maior parte dessas variações, garantindo uma melhor precisão na etapa de classificação. Esse conjunto único de amostra foi utilizado tanto para o treinamento dos diferentes algoritmos testados na área piloto quanto para a classificação de toda a área.

Figura 2.8 – Número de amostra de treinamento por classe

AGLE		AGPE		PL		PS	
Agriculturas de larga escala <b>Amostras: 171</b>		Agriculturas de pequena escala <b>Amostras: 190</b>		Pasto limpo <b>Amostras: 173</b>		Pasto sujo ou com regeneração <b>Amostras: 178</b>	
VSI		VSA		URB		OT	
Vegetação secundária Inicial <b>Amostras: 172</b>		Vegetação secundária avançada <b>Amostras: 170</b>		Área Urbana <b>Amostras: 191</b>		Outros <b>Amostras: 172</b>	
AGUA				PSI			
Rios e demais fluxos d'água <b>Amostras: 176</b>				Tanques de criação de peixes <b>Amostras: 160</b>			

Fonte: Produção do autor (2024)

#### 2.2.4 Classificação

Depois de coletar as amostras, a classificação foi feita em duas fases, utilizando as ferramentas fornecidas pelo pacote SITS (CÂMARA et al., 2024). A primeira consistiu em um primeiro experimento na área piloto, que corresponde ao tile 22 MFC, para testar diferentes classificadores. Esse teste na área piloto foi importante para descobrir qual modelo de classificação traria o melhor resultado. Após identificar o classificador com maior acurácia, ele foi então aplicado à área inteira de estudo. No processo final, o modelo foi ajustado para a área como um todo.

O *Random Forest* é um algoritmo de aprendizado de máquina que é usado tanto para classificação quanto de regressão. O algoritmo cria várias árvores de decisão (*decision trees*) durante o treinamento e combina suas previsões para obter um resultado mais preciso e robusto. Cada árvore é construída usando amostras aleatórias do conjunto de dados de treinamento e um subconjunto aleatório das características (atributos). A combinação das previsões das árvores ajuda a evitar o *overfitting* (ajuste excessivo) e a melhorar a generalização do modelo (BREIMAN, 2001).

*Support Vector Machine* (SVM), é um algoritmo de classificação em que sua base é fundamentada nos princípios de Minimização de Risco Estrutural (Structural Risk Minimization – SRM) (VAPNIK, 1999). O algoritmo tem como objetivo otimizar a performance do modelo minimizando tanto o risco empírico, relacionado ao conjunto de

treinamento, quanto o risco de generalização, associado ao conjunto de testes. O risco empírico refere-se à capacidade do modelo de aprender padrões dos dados de treinamento, enquanto o risco de generalização avalia sua habilidade de prever dados não observados durante o treinamento. Um modelo superajustado pode sofrer de sobreajuste (*overfitting*), comprometendo sua eficácia com novos dados. O SVM é classificador linear binário não probabilístico que procura encontrar um hiperplano de separação que maximize a margem entre classes, aumentando a robustez e a capacidade de generalização do classificador. Assim, é fundamental escolher parâmetros adequados e implementar estratégias de validação eficazes para equilibrar o risco empírico e o de generalização (VAPNIK, 1999).

O algoritmo *Temporal Convolutional Neural Network* (TempCNN), foi criado com o objetivo de incluir de forma mais eficiente a dimensão temporal em modelos de aprendizado de máquina e extrair o máximo de informações das séries temporais. Essa arquitetura é especialmente projetada para lidar com dados temporais, sendo amplamente utilizada na análise de séries temporais de imagens de satélite. Uma de suas principais características é a aplicação de camadas evolucionais na dimensão temporal, o que permite ao modelo identificar padrões que se desenvolvem ao longo do tempo, como mudanças sazonais, crescimento de vegetação ou transformações na cobertura do solo. Isso é fundamental para dados de sensoriamento remoto, que apresentam variações contínuas no tempo e no espaço. (PELLETIER et al., 2019). O TempCNN consegue capturar de forma eficaz as dependências temporais em grandes intervalos de tempo. Isso resulta em um processamento de dados sequenciais, permitindo a extração de padrões complexos e a identificação de variações temporais em larga escala, como as observadas no monitoramento ambiental (PELLETIER et al., 2019).

O *Lightweight Temporal Self-Attention Encoder* (L-TAE) foi desenvolvido para otimizar a classificação de séries temporais de imagens de satélite, combinando eficiência computacional com uma capacidade de memória aprimorada. Sua arquitetura é projetada para processar grandes volumes de dados temporais de forma eficaz, permitindo a análise de mudanças sutis e padrões dinâmicos ao longo do tempo. O L-TAE utiliza um mecanismo de *self-attention* (GARNOT et al., 2020), que distribui os canais das entradas temporais entre várias cabeças de atenção compactas, que operam

em paralelo para extrair características temporais altamente especializadas. Isso possibilita a identificação de correlações temporais complexas sem sobrecarregar o modelo com um número excessivo de parâmetros. Comparado a outros algoritmos de classificação de séries temporais, o L-TAE oferece melhorias significativas em termos de precisão e eficiência computacional, consumindo menos recursos e permitindo a implementação em ambientes com recursos limitados. Essa abordagem, que divide os canais de entrada entre diferentes cabeças de atenção, captura uma diversidade maior de padrões temporais, aumentando a robustez e a adaptabilidade do modelo a diferentes tipos de séries temporais (SAINTE et al., 2020).

### **2.2.5 Avaliação da classificação**

A avaliação da classificação é uma etapa importante na avaliação da acurácia de mapas de cobertura da terra gerados a partir de dados de sensoriamento remoto. O estudo de Olofsson et al. (2014) fornece diretrizes essenciais para avaliação de mapas de classificação que são importantes para a confiabilidade dos resultados. Este trabalho adota essas boas práticas na avaliação do mapa de uso e cobertura da terra gerada, utilizando uma abordagem de amostragem aleatória estratificada por classe.

Para a avaliação das classificações dos algoritmos, foram coletadas 1.168 amostras (pixels), utilizadas para todos os algoritmos. Essas amostras foram distribuídas de forma proporcional à área de cada classe no mapa classificado, seguindo a recomendação de Olofsson et al. (2014) para amostragem aleatória estratificada. Esta estratégia assegura que todas as classes de uso e cobertura da terra sejam representadas adequadamente na amostra de validação, minimizando possíveis vieses e garantindo uma avaliação precisa do mapa.

A matriz de confusão foi construída para quantificar a acurácia de usuário e produtor e, conseqüentemente, os erros de omissão e comissão de cada classe de cobertura da terra. Esta matriz é fundamental para a avaliação dos erros e fornece informações detalhadas sobre quais classes estão sendo confundidas. A partir da matriz de confusão, foram calculadas a acurácia global e as acurácias de usuário e produtor para cada classe. Esses índices são importantes para identificar classes com menor e maior acurácia e orientar melhorias futuras no processo de classificação (OLOFSSON et. al., 2014).

### 3. RESULTADOS E DISCUSSÃO

#### 3.1 Resultados da Classificação e Avaliação de Acurácia

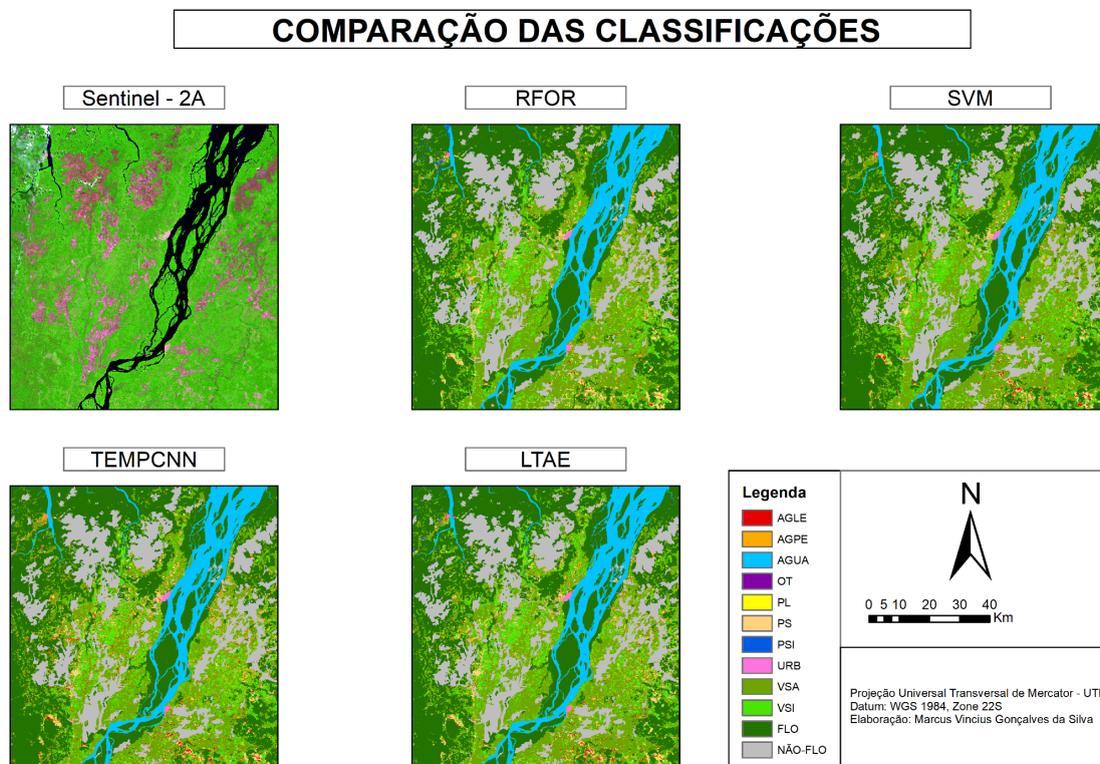
Nesta seção, são apresentados os resultados obtidos com base nos testes realizados.

Utilizando o mesmo conjunto de amostra, apresentado na figura 2.8, foi gerada a classificação para a área de estudo utilizando os classificadores separadamente, para que assim fosse possível realizar uma comparação estatística entre eles.

Foram utilizadas as máscaras do PRODES (2017) de floresta representada na legenda pela classe *FLO* e a máscara de não floresta, que é representada pela classe *NÃO-FLO*, para melhor representar a paisagem local, evitando confusões do classificador com classes que são delimitadas por meio dessas máscaras.

Na classificação da área piloto (tile 22MFC) foram utilizados diferentes algoritmos de classificação. A Figura 3.1 apresenta o resultado das classificações de cada algoritmo utilizado.

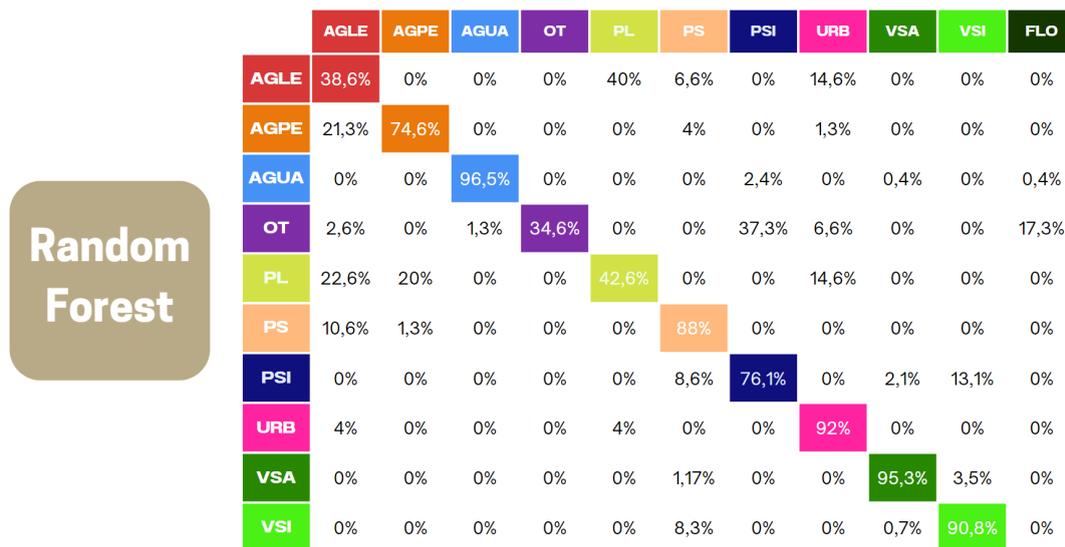
Figura 3.1 - Classificação da área piloto



Fonte: Produção do autor (2024)

Para avaliar os resultados das classificações foram geradas matrizes de confusão para cada algoritmo, possibilitando compreender as principais confusões e índices de acurácia entre as classes mapeadas.

Figura 3.2 - Matriz de confusão RFOR



Fonte: Produção do autor (2024)

No classificador RFOR, a classe AGPE foi frequentemente confundida com AGLE (21,3%), enquanto a classe VSA apresentou confusão com VSI (3,5%) e a classe VSI confundiu-se com PS (8,3%). Essas confusões refletem a transição gradual entre as classes, ocorrendo particularmente pela dificuldade em separar diferentes estágios da vegetação. A classe pasto limpo (PL) também apresentou confusões significativas, especialmente com AGLE (22,6%), AGPE (20%) e URB (14,6%). Apesar dessas confusões, o RFOR alcançou uma acurácia global de 81,33% e coeficiente Kappa de 0,68. A acurácia do produtor e do usuário para AGPE foram 77,8% e 74,7%, respectivamente; para VSA, 99,8% e 95,3%; e para VSI, 86,8% e 90,8%.

Figura 3.3 – Matriz de confusão SVM



	AGLE	AGPE	AGUA	OT	PL	PS	PSI	URB	VSA	VSI	FLO
AGLE	57,3%	5,3%	0%	0%	28%	4%	0%	4%	1,3%	0%	0%
AGPE	12%	64%	0%	0%	1,3%	9,3%	0%	0%	10,6%	2	2,6%
AGUA	0%	0%	97,5%	0%	0%	0,9%	0%	0%	0,9%	0%	0,5%
OT	5,3%	0%	33,3%	41,3%	0%	0%	1,3%	1,3%	0%	0%	17,3%
PL	29,3%	1,3%	0%	12,3%	24%	10,6%	0%	22,6%	0%	0%	0%
PS	4%	5,3%	0%	0%	0%	62,6%	1,3%	0%	10,6%	16%	0%
PSI	0%	2,1%	0%	0%	0%	2,1%	76%	0%	8,6%	10,8%	0%
URB	2,6%	1,3%	0%	0%	2,6%	0%	0%	93,3%	0%	0%	0%
VSA	0%	0%	0%	0%	0%	0,5%	0%	0%	90,2%	9%	0,2%
VSI	0,7%	0%	0%	0%	0%	3,8%	0%	0%	17,5%	77,8%	0%

Fonte: Produção do autor (2024)

No classificador SVM, a classe AGPE apresentou confusão com AGLE (12%), enquanto a classe VSA foi confundida com VSI (9%), enquanto a classe VSI mostrou uma confusão mais acentuada com VSA (17,5%). A classe PL apresentou baixo desempenho, com acurácia de apenas 24%, resultado de confusões com AGLE e URB, possivelmente devido à presença de solo exposto. A acurácia global do SVM foi de 76,78%, com coeficiente Kappa de 0,64. A acurácia do produtor e do usuário para AGPE foram 81,3% e 64%; para VSA, 86,9% e 90,3%; e para VSI, 77,8% e 67,5%.

Figura 3.4 – Matriz de confusão LTAE

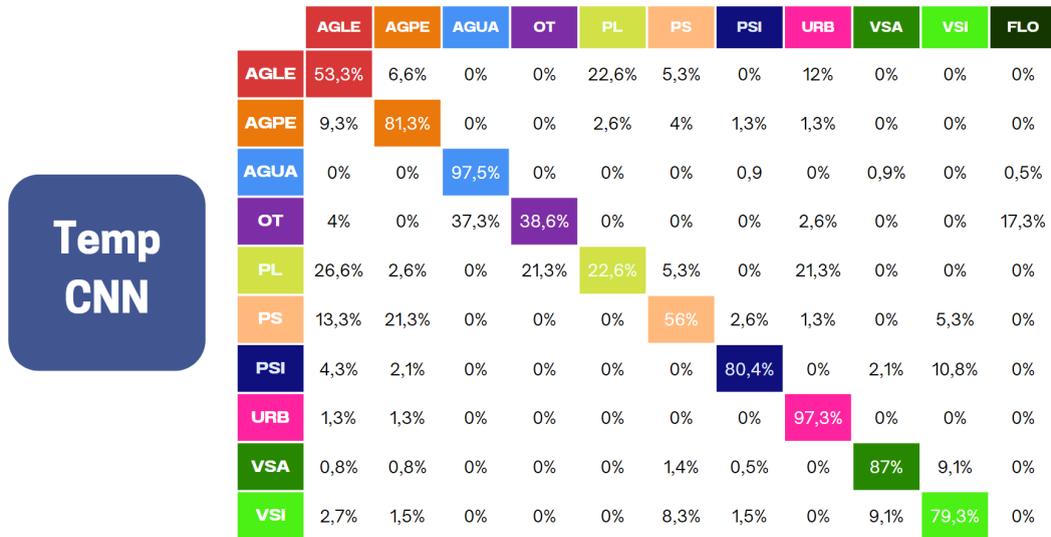


	AGLE	AGPE	AGUA	OT	PL	PS	PSI	URB	VSA	VSI	FLO
AGLE	56%	2,6%	0%	0%	28%	6,6%	1,3%	5,3%	0%	0%	0%
AGPE	13,3%	73,3%	0%	0%	0%	6,6%	0%	1,3%	4%	1,3%	0%
AGUA	0%	0%	98%	0%	0%	0%	0,5%	0%	0,5%	0%	0,9%
OT	5,3%	0%	29,3%	44%	0%	0%	0%	4%	0%	0%	17,3%
PL	16%	2,6%	0%	0%	40%	4%	0%	37,3%	0%	0%	0%
PS	6,6%	9,3%	0%	0%	0%	74,6%	2,6%	0%	4%	2,6%	0%
PSI	8,6%	0%	0%	0%	0%	0%	76,1%	0%	4,3%	10,8%	0%
URB	0%	2,6%	0%	0%	0	0%	0%	97,3%	0%	0%	0%
VSA	0%	0%	0%	0%	0%	2%	0,8%	0%	88,5%	8,2%	0,2%
VSI	0,7%	0%	0%	0%	0%	5,3%	0,7%	0%	12,2%	80,9%	0%

Fonte: Produção do autor (2024)

No classificador LTAE, as confusões seguiram um padrão semelhante aos demais, com a AGPE se confundindo com AGLE (13,3%), VSA com VSI (8,2%) e VSI com VSA (12,2%). A classe PL, novamente, teve um desempenho baixo, com acurácia de 40%, e confusões com URB (37,3%) e AGLE (16%), reforçando as confusões associadas à presença de solo exposto. A acurácia global foi de 79,45%, com coeficiente Kappa de 0,66. As acurácias do produtor e do usuário para AGPE foram, respectivamente, de 80,8% e 73,3%.; para VSA, 92,3% e 88,5%; e para VSI, 74,6% e 80,9%.

Figura 3.5 – Matriz de Confusão TempCNN



Fonte: Produção do autor (2024)

Por fim, o classificador TempCNN também apresentou confusões entre AGPE e AGLE (9,3%), VSA e VSI (9,1%), e VSI com VSA (9,1%). A classe PL continuou a apresentar índices baixos, com confusões frequentes com AGLE (26,6%) e a classe Outros (21,3%), além de uma acurácia baixa de 22,6%. A acurácia global do TempCNN foi de 70,37%, com coeficiente Kappa de 0,65. A acurácia do produtor e do usuário para AGPE foram, respectivamente, 87,5% e 81,3%; para VSA, 95,2% e 87,1%; e para VSI, 72,2% e 79,3%.

Em geral, o RFOR foi o classificador que apresentou melhor resultado em relação ao mapeamento da região de estudo, quando comparado com os demais utilizados, o que fez com que ele fosse escolhido para a classificar toda a área de estudo.

Tabela 3.1 - Comparação geral dos classificadores

	Exatidão global	Kappa
<b>RFOR</b>	81,33%	0,68
<b>SVM</b>	76,78%	0,64
<b>LTAE</b>	79,45%	0,66
<b>Temp CNN</b>	70,37%	0,65

Fonte: Produção do autor (2024)

Tabela 3.2 - Comparação por classe de interesse dos classificadores

<b>Classe: AGPE</b>	<b>Acurácia do produtor</b>	<b>Acurácia do Usuário</b>
<b>RFOR</b>	77,8%	74,7%
<b>SVM</b>	81,3%	64%
<b>LTAE</b>	80,8%	73,3%
<b>Temp CNN</b>	87,5%	81,3%
<b>Classe: VSA</b>	<b>Acurácia do produtor</b>	<b>Acurácia do Usuário</b>
<b>RFOR</b>	99,8%	95,3%
<b>SVM</b>	86,9%	90,3%
<b>LTAE</b>	92,3%	88,5%
<b>Temp CNN</b>	95,2%	87,15
<b>Classe: VSI</b>	<b>Acurácia do produtor</b>	<b>Acurácia do Usuário</b>
<b>RFOR</b>	86,8%	90,8%
<b>SVM</b>	77,8%	67,5%
<b>LTAE</b>	74,6%	80,9%
<b>Temp CNN</b>	72,2%	79,3%

Fonte: Produção do autor (2024)

Embora a classificação utilizando o Random Forest (RFOR) tenha apresentado algumas confusões entre as classes AGPE, AGLE, PL, VSA e VSI, o desempenho geral do algoritmo foi superior aos outros métodos testados, atingindo uma acurácia global de 81,3%. O RFOR demonstrou as maiores acurácias do produtor e do usuário para as classes VSA e VSI, destacando-se no mapeamento dessas categorias. Embora para classe AGPE seu valor de acurácia do produtor tenha sido inferior a outros classificadores, sua acurácia global se manteve alta, quando comparamos com os demais algoritmos. Importante destacar que a acurácia do usuário só não foi mais alta do que a do algoritmo Temp CNN. A classe AGPE, representada em sua maioria pelo

roçado que se baseia em sistemas de roçado de corte e queima, com evidente comportamento temporal, é melhor detectada por esse algoritmo, que inclui a dimensão temporal como atributo para a classificação.

Em diversos estudos relacionados com a classificação do uso e cobertura da terra o RFOR também se destaca em termos de acurácia global. No estudo de Adugna, Xu e Fan (2022), compararam o desempenho do RFOR com o SVM. O RFOR alcançou uma acurácia global maior, demonstrando uma maior capacidade de generalização ao lidar com dados de sensoriamento remoto. A habilidade de manejar grandes volumes de dados e variáveis complexas, que muitas vezes sobrecarregam outros algoritmos, garante ao RFOR um desempenho consistente, principalmente em tarefas relacionadas ao mapeamento do uso e cobertura da terra.

Além disso, o estudo de Mutale et al. (2024) aponta que o RFOR superou tanto as Redes Neurais Artificiais (ANN) quanto o SVM em termos de acurácia e coeficiente Kappa em dois casos de estudo distintos. A pesquisa comparou o desempenho dos algoritmos na classificação de mudanças no uso e cobertura da terra e observou que o RFOR manteve acurácias entre 0,92 e 0,97, mostrando uma precisão superior. Esses resultados destacam a robustez do RFOR em diversos contextos e reafirmam sua eficácia em análises geoespaciais, além de sua capacidade de reduzir erros de classificação.

Por fim, o trabalho de Pacifici et al. (2008) também apresenta melhores resultados do RFOR em comparação com a TempCNN. Embora a TempCNN tenha demonstrado uma boa capacidade de captação de características que variam ao longo do tempo, dentro de uma classe, para a classificação de uso e cobertura da terra, o RFOR continuou a obter resultados ligeiramente melhores em termos de acurácia global. Isso reforça a escolha de pesquisadores no uso do RFOR para mapeamentos em áreas diversas e complexas. A adoção do RFOR em estudos que utilizam plataformas como a do Google Earth Engine reflete sua capacidade de fornecer resultados consistentes, tornando-o uma escolha confiável para classificação de grandes áreas.

### 3.2 Análise do uso e cobertura da terra da Região do Baixo Tocantins em 2017

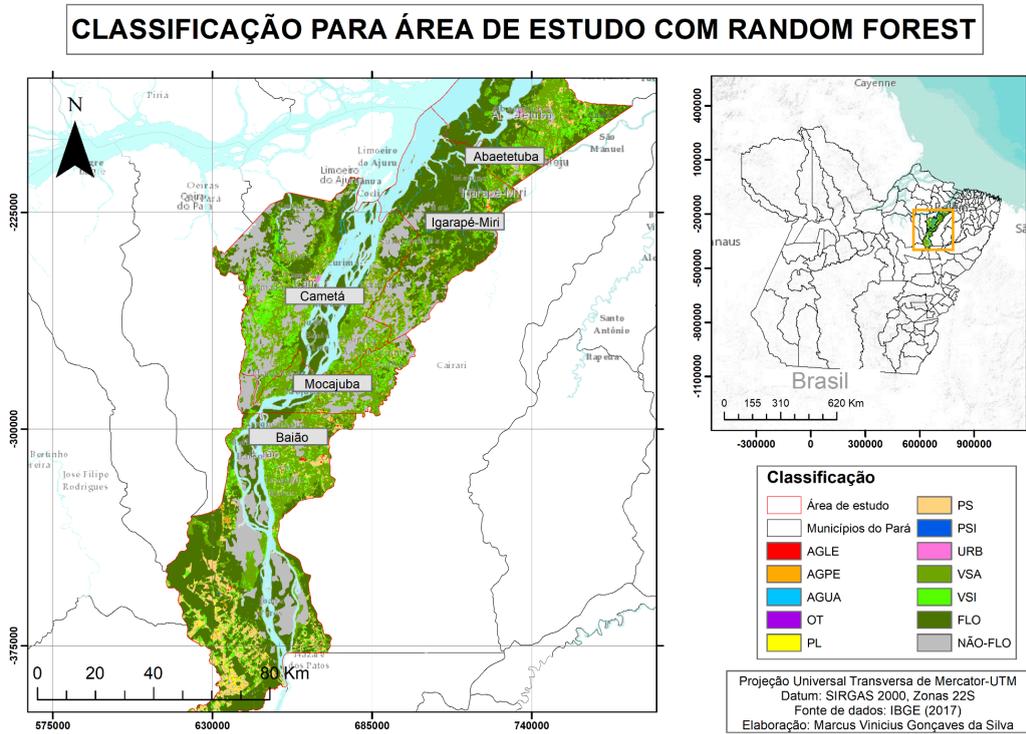
A análise realizada sobre o mapeamento da área de estudo revela que a classe AGPE abrange 9.709 hectares, enquanto a classe VSI ocupa 96.734 hectares e a classe VSA se estende por 260.276 hectares (Tabela 3.3 e Figuras 3.6 e Figura 3.7). Essas classes, associadas em grande parte à AGPE, destacam a relevância da agricultura camponesa em relação às demais classes de uso da terra na região, sublinhando a importância e necessidade de seu monitoramento.

Tabela 3.3 - Área das classes de uso e cobertura da terra mapeadas com o RFOR para o ano de 2017.

Classe	Área (ha)
AGLE	3.592
AGPE	9.709
AGUA	148.153
OT	40
PL	3.724
PS	65.555
PSI	951
URB	3.167
VSA	260.276
VSI	96.734
FLO	386.829
NÃO-FLO	151.361

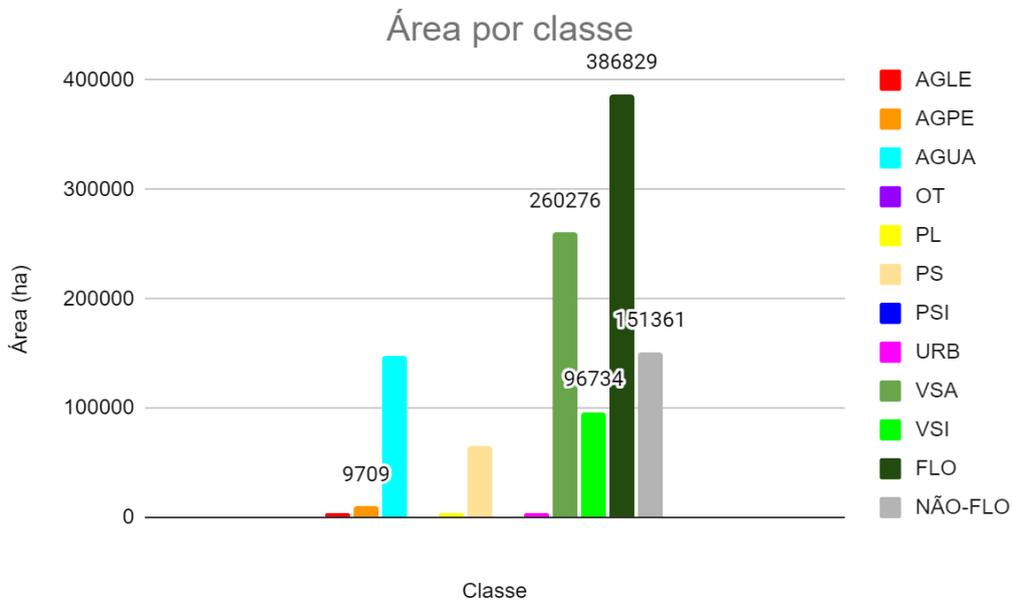
Fonte: Produção do autor (2024)

Figura 3.6- Mapa de uso e cobertura da terra.



Fonte: Produção do autor (2024)

Figura 3.7- Área de cada classe



Fonte: Produção do autor (2024)

O mapeamento das classes de vegetação secundária e agricultura de pequena escala são fundamentais para que se possa avaliar a distribuição e dinâmicas de terras cultivadas e suas proporções em relação ao total da área mapeada. Os dados do IBGE revelam que aproximadamente 12% da população brasileira reside na zona rural, com uma parte significativa dessa população composta por agricultores familiares, que desempenham um papel importante na produção de alimentos e na preservação da cultura local (IBGE, 2022).

A complementação dos resultados obtidos em outras bases de dados, como as do IBGE, auxilia na discussão sobre as políticas públicas principalmente em relação às categorias camponesas. O mapeamento da AGPEs na região do Baixo Tocantins revela que as áreas ocupadas pela agricultura camponesa e a vegetação secundária são subestimadas de uma forma geral e, portanto, sua contribuição para a economia local e para a conservação ambiental também é subestimada. A integração dessas informações auxilia no entendimento sobre esses sistemas agrários e em seu papel nas dinâmicas agrárias, podendo subsidiar a formulação de políticas públicas inclusivas e diferenciadas que visem o fortalecimento da agricultura camponesa, promovendo o desenvolvimento inclusivo e ambientalmente sustentável na região.

#### **4. CONCLUSÃO**

O mapeamento da AGPE realizado para a área de estudo é complexo e isso ocorre principalmente devido à diversidade de usos da terra e pelo pequeno tamanho e diversidade das áreas cultivadas, especialmente em sistemas de roçados. Esse modelo de sistema demonstra a importância de se identificar a diferença entre os diferentes estágios de vegetação secundária devido à sua ligação com a recuperação de áreas de vegetação nativa, podendo assim, auxiliar na análise do processo de restauração de áreas florestais na região. A utilização de tecnologias de sensoriamento remoto, como o uso de imagens do Sentinel-2, com resolução espacial (10 m) inferior a do OLI/Landsat (30 m), possibilitou capturar áreas menores que 2 hectares, que é comum nas práticas camponesas na região de estudo. Além disso, o uso de cubos de dados foi um aspecto

relevante desta metodologia, permitindo capturar as variações temporais associadas aos diferentes estágios da vegetação e de crescimento dos cultivos.

Desse modo, é necessário realizar a validação da classificação para toda a área de estudo, já que os valores de acurácia e índice Kappa podem sofrer alterações devido aos diferentes padrões da paisagem, contida em cada município. Sendo assim, a validação estratificada realizada na área piloto, para os diferentes classificadores, também deverá ser aplicada para a classificação final da área de estudo como um todo.

Os índices de acurácia global e o valor do índice Kappa obtidos com o algoritmo RFOR demonstram que a metodologia desenvolvida para a área piloto pode ser replicada em toda a área de estudo. Além disso, os resultados demonstram a viabilidade em incluir e diferenciar as classes AGPE, AGLE, VSA e VSI nos mapas de uso e cobertura da terra, possibilitando sua expansão para outras regiões da Amazônia.

Considerando que o algoritmo *Convolutional Neural Network* (TempCNN) demonstrou a melhor acurácia para a classe AGPE, uma estratégia para aprimorar o mapeamento desta classe, seria a combinação dos mapas de probabilidades gerados pelos algoritmos RFOR e TempCNN. Essa abordagem integrada poderia aumentar a precisão dos resultados, em especial da AGPE. Além disso, a utilização de outros índices, como textura e EVI (*Enhanced Vegetation Index*), poderia enriquecer a análise, fornecendo informações adicionais para melhor distinguir as classes de AGPE, AGLE, VSI e VSA. A obtenção de dados de campo como referência também seria uma etapa importante para avaliar e calibrar as amostras de treinamento e teste, garantindo maior precisão das amostras e consequentemente do mapeamento.

Com a análise realizada, demonstrou-se o potencial das imagens Sentinel e dos algoritmos avaliados, em diferenciar a AGPE das categorias de maior escala, além da diferenciação da vegetação secundária, separando-a em estágios inicial e avançado. A AGPE apresentou 9.709 ha, uma área 2,7 vezes maior que a Agricultura de Larga Escala, o que aponta para sua grande importância na região. Além disso, a vegetação secundária, que frequentemente está associada às práticas de roçado, ou seja, à agricultura camponesa, apresentou uma área de cerca de 357.000 ha, mostrando a relevância desses sistemas na conservação da vegetação e nos processos de restauração

da vegetação nativa. Com o mapeamento e a diferenciação dessas classes, torna-se possível elaborar políticas inclusivas, diferenciadas e, portanto, mais adequadas que possam atender às demandas da agricultura camponesa, fortalecendo-a e aumentando sua capacidade de proteção dos recursos florestais.

## 5. BIBLIOGRAFIA

ADUGNA, T.; XU, W.; FAN, J. Comparison of Random Forest and Support Vector Machine Classifiers for Regional Land Cover Mapping Using Coarse Resolution FY-3C Images. **Remote Sensing**, v. 14, p. 574, 2022. Disponível em: <https://doi.org/10.3390/rs14030574>. Acesso em: 11 out. 2024.

ALMEIDA, R. Amazônia, Pará e o mundo das águas do Baixo Tocantins. **Estudos Avançados**, v. 24, n. 68, p. 291–298, 2010.

BAYLE, A.; CARLSON, B. Z.; THIERION, V.; ISENMANN, M.; CHOLER, P. Improved Mapping of Mountain Shrublands Using the Sentinel-2 Red-Edge Band. **Remote Sensing**, v. 11, n. 23, 2019. <https://doi.org/10.3390/rs11232807>.

BOSERUP, E. The conditions of agricultural growth: The economics of agrarian change under population pressure. **The Conditions of Agricultural Growth: The Economics of Agrarian Change Under Population Pressure**, p. 1–124, 2013. <https://doi.org/10.4324/9781315016320>.

BREIMAN, L. Random Forests. **Machine Learning**. Kluwer Academic Publishers, v. 45, p. 5-32, 2001.

BRONDÍZIO, E. S. Açaí palm fruit: From a staple to fashionable food. In: BRONDÍZIO, E. S. (Ed.). **The Amazonian Caboclo and the açai palm: Forest Farmers in the Global Market**. New York: New York Botanical Garden Press, 2008. p. 402.

MUTALE, Bwalya; WITHANAGE, Neel Chaminda; MISHRA, Prabuddh Kumar; SHEN, Jingwei; ABDELRAHMAN, Kamal; FNAIS, Mohammed S. A performance evaluation of random forest, artificial neural network, and support vector machine learning algorithms to predict spatio-temporal land use-land cover dynamics: a case from Lusaka and Colombo. **Frontiers in Environmental Science**, v. 12, 2024. DOI: 10.3389/fenvs.2024.1431645. Disponível em: <https://www.frontiersin.org/journals/environmental-science/articles/10.3389/fenvs.2024.1431645/full> . 2024.1431645/full. Acesso em: 14 out. 2024.

PACIFICI, Fabio et al. Neural Networks for Land Cover Applications. In: **Computational Intelligence for Remote Sensing**. Berlin: Springer, 2008. v. 133. ISBN 978-3-540-79352-6. Disponível em: [https://link.springer.com/chapter/10.1007/978-3-540-79353-3\\_11](https://link.springer.com/chapter/10.1007/978-3-540-79353-3_11). Acesso em: 14 out. 2024.

CÂMARA, Gilberto et al. Sits: Satellite Image Time Series Analysis on Earth Observation Data Cubes. [Data da última compilação: 21 de junho de 2023].

COSTA, F. DE A. Contributions of fallow lands in the Brazilian Amazon to CO2 balance, deforestation and the agrarian economy: Inequalities among competing land use trajectories. **Elementa: Science of the Anthropocene**, v. 4, 2016.

COSTA, F. de A.; CIASCA, B. S.; CASTRO, E. C. C.; BARREIROS, R. M. M.; FOLHES, R.; BERGAMINI, L. L.; SOLYNO SOBRINHO, A.; CRUZ, A.; COSTA, A.; SIMÕES, J.; ALMEIDA, J. S.; SOUZA, H. M. de. Socio-biodiversity Bioeconomy in the State of Pará. Brasília-DF: The Nature Conservancy (TNC Brasil), Banco Interamericano de Desenvolvimento (BID), Natura, 2021.

COSTA, F. de A.; NOBRE, C.; GENIN, C.; MEDEIROS ROCHA FRASSON, C.; ARAÚJO FERNANDES, D.; SILVA, H.; VICENTE, I.; TAKAES SANTOS, I.; FELTRAN-BARBIERI, R.; VENTURA NETO, R.; FOLHES, R. Uma bioeconomia inovadora para a Amazônia: conceitos, limites e tendências para uma definição apropriada ao bioma floresta tropical. World Resources Institute, 2022. DOI 10.46830/wriwp.21.00168pt. Disponível em: <https://wribrasil.org.br/publicacoes/uma-bioeconomia-inovadora-para-amazonia-conceitos-limites-e-tendencias-para-uma>.

CUNHA, M. A. Sensoriamento remoto para sistemas agrários associados à produção de açaí na região do baixo Tocantins, PA. 2023. Dissertação em Sensoriamento Remoto – Instituto Nacional de Pesquisas Espaciais-INPE, São José dos Campos, 2023.

FILIPPONI, F. BAIS2: Burned Area Index for Sentinel-2. **Proceedings**, v. 2, n. 7, p. 364, 2018. <https://doi.org/10.3390/ecrs-2-05177>.

GARNOT, V. S. F.; LANDRIEU, L. Lightweight Temporal Self-attention for Classifying Satellite Images Time Series. 2020. Advanced Analytics and Learning on Temporal Data [...]. Cham: Springer International Publishing, 2020. p. 171–181.

Gilberto Camara, Rolf Simoes, Felipe Souza, Felipe Carlos, Charlotte Pelletier, Pedro R. Andrade, Karine Ferreira, and Gilberto Queiroz (2024). Satellite Image Time Series Analysis on Earth Observation Data Cubes. National Institute for Space Research (INPE), Brazil. Online book available at <https://github.com/e-sensing/sitsbook>. DOI: 10.5281/zenodo.13381515.

GOMES, F. F.; GARCIA, G. J.; SILVA, J. K. Comercialização do açaí no estado do Pará: alguns comentários. **Observatorio de la Economía Latinoamericana**, 2015.

**GOOGLE EARTH**. Imagens de satélite: Agência Espacial Francesa Centre National d'Études Spatiales - CNES. 2021. Disponível em: <https://earth.google.com>.

HU, F.; XIA, G.; HU, J.; ZHANG, L. Transferring deep convolutional neural networks for the scene classification of high-resolution remote sensing imagery. **Remote Sensing**, v. 7, n. 11, p. 14680–14707, 2015a.

IBGE. Cidades e Estados. Disponível em: <https://www.ibge.gov.br/cidades-e-estados.html?view=municipio>. Acesso em: 29 mar. 2023.

IBGE. Malha Municipal Digital da Divisão Político-Administrativa Brasileira 2022. Disponível em: <https://biblioteca.ibge.gov.br/index.php/biblioteca-catalogo?view=detalhes&id=2101998>.

INPE. TerraClass. Disponível em: [http://www.inpe.br/cra/projetos\\_pesquisas/dados\\_terraclass.php](http://www.inpe.br/cra/projetos_pesquisas/dados_terraclass.php). Acesso em: 31 dez. 2023.

INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite - PRODES. 2017.

Disponível em: <http://www.obt.inpe.br/OBT/assuntos/programas/amazonia/prodes>.  
Acesso em: 4 mar. 2023.

INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA - IBGE. Censo Demográfico 2022: Resultados Preliminares. Rio de Janeiro, 2022. Disponível em: [www.ibge.gov.br](http://www.ibge.gov.br). Acesso em: 11 out. 2024.

KOUTSIAS, N.; KARTERIS, M. Logistic regression modeling of multi-temporal Thematic Mapper data for burned area mapping. **International Journal of Remote Sensing**, v. 19, p. 3499–3514, 1998. pp. 3499-3514. Doi: <https://doi.org/10.1080/014311698213777>.

LUZ, N. B. da et al. Manual de Análise de Paisagem: Volume 2. Procedimentos Para a Execução Do Controle de Qualidade Do Mapeamento de Uso e Cobertura Da Terra. 2018.

MARTINOT, J. F. et al. Coletar ou cultivar: as escolhas dos produtores de açaí-da-mata (Euterpe precatoria) do Amazonas. **Revista De Economia E Sociologia Rural**, v. 55, n. 4, p. 751–766, 2017. Disponível em: <https://doi.org/10.1590/1234-56781806-94790550408>.

MENEZES, L. C.; SANTOS, L. G. B. Sensoriamento remoto e geoprocessamento aplicados ao estudo da vegetação. **Oficina de Textos**, 2010.

**MICROSOFT PLANETARY COMPUTER**. Data Catalog. 2022. Disponível em: <https://planetarycomputer.microsoft.com/catalog>.

MONARD, Maria Carolina; BARANAUSKAS, José Augusto. Conceitos Sobre Aprendizado de Máquina. **\*\*Sistemas Inteligentes Fundamentos**