U.PORTO
FACULDADE DE CIÊNCIAS
UNIVERSIDADE DO PORTO

PhD

3.º
CICLO

FCUP
2024

U.PORTO

Inteligência Artificial para analisar o Desmatamento na Região Amazônica Brasileira

Lena Patricia Souza Rodrigues

FC

U.PORTO
FACULDADE DE CIÊNCIAS
UNIVERSIDADE DO PORTO

Inteligência Artificial para analisar o desmatamento na Região Amazônica Brasileira

Lena Patricia Souza Rodrigues
Ciência e Tecnologia do Ambiente
Departamento de Geociências, Ambiente e Ordenamento do Território
Ano: 2024

PhD

Inteligência Artificial para analisar o desmatamento na Região Amazônica Brasileira

Lena Patricia Souza Rodrigues
Ciência e Tecnologia do Ambiente
Departamento de Geociências, Ambiente e Ordenamento do Território
Ano: 2024

Orientador
Joaquim E. da Silva, Professor Catedrático, Universidade do Porto

Coorientador
Hieda Silva, Professora Adjunta, Universidade Federal do Pará

Todas as correções determinadas pelo júri foram efetuadas.

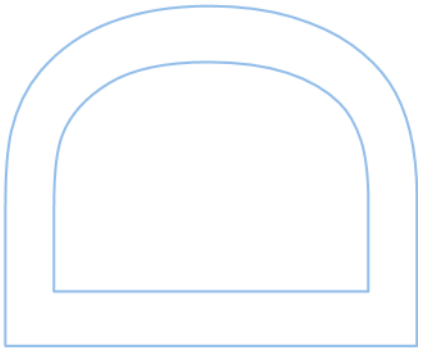

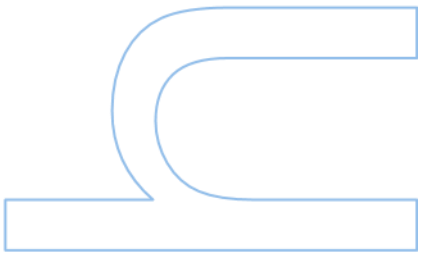

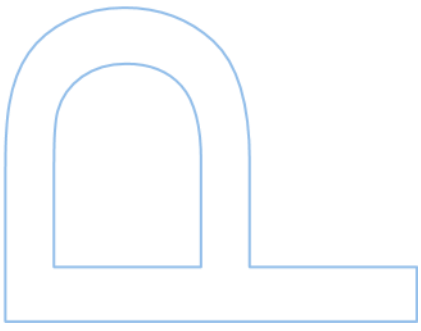

Dedicatória

Dedico carinhosamente esse trabalho a minha vovozinha Iracema Maria!

Declaração de Honra

Eu, Lena Patricia Souza Rodrigues, inscrito(a) no Programa Doutoral em Ciência e Tecnologia do Ambiente da Faculdade de Ciências da Universidade do Porto declaro, nos termos do disposto na alínea a) do artigo 14.º do Código Ético de Conduta Académica da U.Porto, que o conteúdo da presente tese reflete as perspetivas, o trabalho de investigação e as minhas interpretações no momento da sua entrega.

Ao entregar esta tese, declaro, ainda, que a mesma é resultado do meu próprio trabalho de investigação e contém contributos que não foram utilizados previamente noutros trabalhos apresentados a esta ou outra instituição.

Mais declaro que todas as referências a outros autores respeitam escrupulosamente as regras da atribuição, encontrando-se devidamente citadas no corpo do texto e identificadas na secção de referências bibliográficas. Não são divulgados na presente tese quaisquer conteúdos cuja reprodução esteja vedada por direitos de autor.

Tenho consciência de que a prática de plágio e auto-plágio constitui um ilícito académico.

Lena Patricia Souza Rodrigues

[Porto, Portugal, 20 de maio de 2024]

Agradecimentos

Agradeço a Deus pela imensa presença durante toda a condução desse estudo. Agradeço a companhia amorosa das minhas duas filhas Diana Souza de Araújo (5 anos) e Sophie Souza de Araújo (2 anos). Agradeço ao meu eterno amigo, companheiro, Diovanni Moraes de Araújo pelo incansável apoio e parceria. Agradeço o apoio de familiares, mãe Izabel Sousa, minhas irmãs Leila Rodrigues e Sheila Rodrigues; Katia Araújo e Gilvandro Araújo. Agradeço a Universidade do Porto, especialmente ao meu Orientador Joaquim Silva e minha coorientadora Hieda Silva. Agradeço a Universidade Federal Rural da Amazônia (Ufra). Agradeço a todos que contribuíram indiretamente para a concretização desta etapa. Agradeço a Lena Patricia Souza Rodrigues, autora deste documento, por não desistir dessa etapa tão importante para o crescimento pessoal, acadêmico e Profissional.

Resumo

Esta tese analisou o desmatamento na Região Amazônica Brasileira, utilizando Inteligência Artificial (IA), Geoprocessamento (GEO) e Sensoriamento Remoto (SR), a partir da classificação de Imagens de satélites, no período de 2001 a 2022. O período definido considerou, custo de processamento do sistema computacional; peculiaridades da área estudada; a disponibilização de dados gerados através do PRODES, desde 2001, considerando as classes, corte raso, queimadas, mineração e áreas de proteção ambiental. Esses dados foram submetidos ao processo de associação vetorial para análises quantitativas por município, no software QGIS 3.10. Este trabalho utilizou três algoritmos de Inteligência Artificial, K-vizinhos mais próximo (KNN), Floresta Aleatória (RF) e Rede Neural Convolucional (RNC). Estes algoritmos foram utilizados para classificar imagens de satélites e gerar parâmetros de identificação de classes de áreas desmatadas, considerando, as classes, corte raso, queimadas, mineração, áreas de proteção ambiental; analisaram as relações entre os tipos de desmatamento, considerando as classes, relacionando-as com processos de antropização ocorridos nos ultimos anos, sobretudo, surgimento de rodovias e atividades de mineração. Os experimentos de classificação de imagens de satélites geraram bons resultados. Os resultados qualitativos foram analisados, a partir da interpretação visual das imagens processadas, ou seja, observações realizadas em imagens de satélite, mapeamento das classes de interesse, assim como observações durante o processo de coleta de amostra para a classificação supervisionada. Os resultados quantitativos foram analisados a partir das métricas Acurácia, Precisão, Recall, F-Score e Kappa Score. Especificamente o estudo realizou uma análise comparativa entre os algoritmos. A Rede Neural Convolucional (RNC) apresentou os melhores resultados, considerando a interpretação visual e os dados processados. A RNC apresentou o melhor desempenho, comparado aos outros métodos, considerando a classificação dos pixels das classes (queimadas, corte raso, mineração, áreas de proteção ambiental); apresentou melhores índices para identificar as classes e melhores índices para as métricas. Os algoritimos KNN, RF apresentaram resultados similares, no entanto, apresentaram desempenho inferior, considerando RNC. Durante as simulações, os algoritmos utilizados, inicialmente, não diferenciaram precisamente áreas de proteção ambiental de áreas verde. Problemas foram detectados na identificação de algumas classes, como áreas de proteção ambiental, queimadas, mineração, devido a natureza espaço-temporal dos dados e das imagens de satélite. Os algoritmos não encontraram, inicialmente, o padrão correto, preciso, considerando a temporalidade dos dados. O modelo de Rede Neural Convolucional apresentou os melhores resultados, apresentou complexidade maior, no campo de imagens espectrais de satélite, diferenças de pixels, resoluções e composições de bandas de satélite. Segundo o PRODES, a taxa de desmatamento computada, no período de 2001 a 2022, na região estudada, corresponde, aproximadamente, 65.830 Km^2. No entanto, os resultados da classificação utilizando a RNC computou, aproximadamente, 68.035 Km^2. Os dados resultantes da classificação utilizando RNC mostraram uma diferença dos dados de desflorestamento, no período de 2001 a 2022, considerando as taxas do PRODES. Esta diferença ocorreu devido a natureza do sistemas que o PRODES utiliza, considerando, questões tecnológicas, como os tipos de sensores óticos utilizados, características físicas da radiação eletromagnética na faixa do espectro visível, por exemplo, o imageamento ótico é bloqueado pela presença de nuvens. Assim como, peculiaridades da região, análise espaço-temporal dos dados, décadas de exploração consecutivas, que causam impactos socio ambientais irreversíveis, imperceptíveis e incalculáveis.

Palavras-chave: Amazônia Brasileira, Inteligência Artificial, Desflorestamento

Abstract

This thesis analyzed deforestation in the Brazilian Amazon Region, using Artificial Intelligence (AI), Geo-processing (GEO), and Remote Sensing (RS), through the classification of satellite images, from the period of 2001 to 2022. The defined period considered the computational system processing cost; peculiarities of the studied area; and the availability of data generated through PRODES since 2001, considering the classes: clear-cutting, burning, mining, and environmental protection areas. These data were subjected to the vector association process for quantitative analyses by municipality, using QGIS 3.10 software. This work employed three Artificial Intelligence algorithms: K-Nearest Neighbors (KNN), Random Forest (RF), and Convolutional Neural Network (CNN). These algorithms were used to classify satellite images and generate parameters for identifying classes of deforested areas, considering the classes: clear-cutting, burning, mining, and environmental protection areas. They analyzed the relationships between the types of deforestation, considering the classes, relating them to anthropization processes occurring in recent years, particularly the emergence of highways and mining activities. The satellite image classification experiments yielded good results. The qualitative results were analyzed based on the visual interpretation of the processed images, with observations made on satellite images, mapping of the classes of interest, as well as observations during the sample collection process for supervised classification. The quantitative results were analyzed based on the metrics Accuracy, Precision, Recall, F-Score, and Kappa Score. Specifically, the study conducted a comparative analysis between the algorithms. The Convolutional Neural Network (CNN) produced the best results, considering visual interpretation and processed data. The CNN showed the best performance compared to the other methods, considering the classification of class pixels (burning, clear-cutting, mining, environmental protection areas); it presented the best indices for class identification and the best indices for the metrics. The KNN and RF algorithms showed similar results; however, they had lower performance compared to CNN. During the simulations, the algorithms initially did not precisely differentiate environmental protection areas from green areas. Problems were detected in identifying some classes, such as environmental protection areas, burning, and mining, due to the spatial-temporal nature of the data and satellite images. The algorithms initially did not find the correct, precise pattern, considering the data temporary. The Convolutional Neural Network model produced the best results and presented greater complexity in the field of spectral satellite images, pixel differences, resolutions, and satellite band compositions. According to PRODES, the computed deforestation rate in the studied region from 2001 to 2022 corresponds to approximately 65,830 km². However, the classification results using CNN computed approximately 68,035 km². The data resulting from the classification using CNN showed a difference from the deforestation data over the period 2001 to 2022, considering PRODES rates. This difference occurred due to the nature of the systems that PRODES uses, considering technological issues, such as the types of optical sensors used, physical characteristics of electromagnetic radiation in the visible spectrum range—for example, optical imaging is blocked by the presence of clouds. Additionally, peculiarities of the region, spatial-temporal analysis of the data, decades of consecutive exploitation, which cause imperceptible, incalculable, and irreversible social and environmental impacts, were also considered.

Keywords: Brazilian Amazon, Artificial Intelligence, Deforestation

Índice

Lista de Tabelas ..... **vii**

Lista de Figuras ..... **viii**

Lista de Abreviaturas ..... **ix**

1. Introdução **1**

1.2. Objetivo 6

1.2.1. Objetivo Geral 6

1.2.2. Objetivos Específicos 6

2. Referencial Teórico **7**

2.1. Desmatamento 7

2.2. Desmatamento e Legislação 10

2.3. Desmatamento na Floresta Amazônica Brasileira 11

2.4. Geoprocessamento e Sensoriamento Remoto 14

2.4.1. Geoprocessamento 14

2.4.2. Sensoriamento Remoto 15

2.5. Inteligência Artificial (IA) 18

2.5.1. Aprendizado de Máquina (AM) 20

2.5.2. Floresta Aleatória (RF) 22

2.5.3. O K-Vizinhos mais próximos (KNN) 23

2.5.4. Rede Neural Convolucional (RNC) 24

2.5.5. Classificação de imagem de satélite da Região Amazônica Brasileira 27

2.5.6. Trabalhos Similares 29

3. Metodologia **31**

3.1. Modelo de Geo-RNC 33

3.2. Modelo Geo-KNN 34

3.3. Modelo Geo-RF 36

3.4. Materiais e Métodos 38

3.5. Classificação de imagens de satélite 41

3.6. Medidas de Desempenho 47
3.6.1. Métricas de Avaliação 47
4. Resultados 50
4.1. Análise de índices de Desmatamento 50
4.2. Resultados KNN, RF e RNC 53
4.2.1. Resultados Random Forest (RF) 54
4.2.2. Resultados KNN 55
4.2.3. Resultados com RNC 56
4.3. Comparação dos resultados das simulações 57
4.4. Desmatamento em Áreas de proteção Ambiental 64
4.5. Análise de Desmatamento e rodovias 67
4.6. Análise de Desmatamento e mineração 68
4.7. Análise de Desmatamento por corte raso e queimadas, considerando rodovias e mineração 69
4.8. Análise de desmatamento e agropecuária industrial 74
5. Conclusão 77
6. Referências 81

Lista de Tabelas

Tabela 1 - Matriz de confusão RF, KNN e RNCb 57
Tabela 2 - Desempenho RNC, KNN, RF 60

Lista de Figuras

Figura 1- Área de estudo1, Brasil....3
Figura 2 - Área de estudo 2, Pará....4
Figura 3 - Área de estudo 3, Altamira e SFX....5
Figura 4 - O modelo RNC....33
Figura 5 - Taxa de desmatamento/desflorestamento acumulado....50
Figura 6 - Resultados RF....54
Figura 7 - Resultados KNN....55
Figura 8 - Resultados RNC....56
Figura 9 - Comparação dos resultados RNC, KNN, RF....59
Figura 10 - Resultado Avaliação Geral por Algoritmo....61
Figura 11 - Resultado Avaliação Geral por Algoritmo....62
Figura 12 - Análise de desflorestamento/desmatamento e APA....64
Figura 13 - Desflorestamento, Corte raso e queimada....65
Figura 14 - Classificação de APA....65
Figura 15 - Analise de Desmatamento, APA e Rodovias....67
Figura 16 - Análise Desmatamento, mineração....68
Figura 17 - Classificação, Desflorestamento, Mineração, APA....69
Figura 18 - Classificação Desflorestamento, Corte raso e queimada....70
Figura 19 - Classificação desflorestamento, rodovias, mineração....71
Figura 20 - Classificação Agropecuária industrial....74

Lista de Abreviaturas

AM	APRENDIZADO DE MÁQUINA
APA	ÁREA DE PROTEÇÃO AMBIENTAL
DEGRAD	MAPEAMENTO DA DEGRADAÇÃO FLORESTAL NA AMAZÔNIA BRASILEIRA
DETER	DETECÇÃO DE DESMATAMENTO EM TEMPO REAL
DETEX	DETECÇÃO DE EXPLORAÇÃO SELETIVA
EVI	ÍNDICE DE VEGETAÇÃO APRIMORADO
GEE	GASES DO EFEITO ESTUFA
GEO	GEOPROCESSAMENTO
GEO-KNN	GEOPROCESSAMENTO, K-VIZINHOS MAIS PRÓXIMOS
GEO-RF	GEOPROCESSAMENTO, FLORESTA ALEATÓRIA
GEO-RNC	GEOPROCESSAMENTO, REDE NEURAL CONVOLUCIONAL
GNDVI	VEGETAÇÃO DE DIFERENÇA NORMALIZADA VERDE
IA	INTELIGÊNCIA ARTIFICIAL
IDH	ÍNDICE DE DESENVOLVIMENTO HUMANO
IDHM	ÍNDICE DE DESENVOLVIMENTO HUMANO DOS MUNICIPIOS
INPE	INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS
MDL	MECANISMO DE DESENVOLVIMENTO LIMPO
MMA	MINISTÉRIO DO MEIO AMBIENTE
NDVI	ÍNDICE DE VEGETAÇÃO COM DIFERENÇA NORMALIZADA
PAS	PLANO DE DESENVOLVIMENTO SUSTENTÁVEL DA AMAZÔNIA
PPCDAM	PLANO DE AÇÃO PARA PREVENÇÃO E CONTROLE DO DESMATAMENTO NA AMAZÔNIA BRASILEIRA
PRODES	PROGRAMA DE MONITORAMENTO DA FLORESTA AMAZÔNICA BRASILEIRA POR SATÉLITE
RF	FLORESTA ALEATÓRIA
RNC	REDE NEURAL CONVOLUCIONAL
SFB	SERVIÇO FLORESTAL BRASILEIRO
SFX	SÃO FÉLIX DO XINGU
SIG	SISTEMA DE INFORMAÇÕES GEOGRÁFICAS
SR	SENSORIAMENTO REMOTO
SUDAM	SUPERINTENDÊNCIA DE DESENVOLVIMENTO DA AMAZÔNIA
TIC	TECNOLOGIA DE INFORMAÇÃO E COMUNICAÇÃO
UCS	UNIDADES DE CONSERVAÇÃO
UP	UNIVERSIDADE DO PORTO
VANT	VEÍCULO AÉREO NÃO TRIPULAD

1. Introdução

A Amazônia Brasileira tem vivenciado diversas transformações ambientais, sociais, políticas, econômicas. Esses processos favorecem, sobretudo, a ocorrência de problemas socioambientais incalculáveis, irreversíveis e insustentáveis. Preservar a floresta Amazônica, assim como, minimizar impactos sobre o desmatamento é indispensável para o equilíbrio de processos relacionados a sociobiodiversidade desta região.

O desmatamento é responsável por 22% das emissões brasileiras de Gases do Efeito Estufa (GEE).[1] O processo de desmatamento na Amazônia Brasileira está associado a fatores de mercado.[2,3] A exploração florestal é caracterizada pelos processos de derrubada de árvores, arraste das toras, abertura de pátio de estocagem e transporte da madeira. Esses processos interferem fortemente na estrutura da floresta.[4] Essa exploração tem ocasionado altos níveis de impacto.

O desmatamento é um problema global com extensas consequências ambientais e económicas, uma vez que reduz a biodiversidade, tem impacto nas alterações climáticas através da emissão de CO_2. O desmatamento, também chamado desflorestamento, é o principal delito ambiental praticado na Amazônia Brasileira.[44]

A principal base de cálculo de crédito de carbono oriundo de redução de desmatamento está vinculada às áreas de floresta e aos estoques de carbono observados e medidos em campo.[11,12] Dados de carbono armazenados, ao longo do tempo, permitem a criação de cenários e predições de estoques. Esta ação pode ser utilizada nas negociações e definição de projetos de exploração florestal e mitigação de gases poluentes.[13] Acompanhar a dinâmica de carbono nas florestas podem interferir fortemente no ciclo global de carbono.[10]

O desmatamento é um agravante ao equilíbrio da região Amazônica Brasileira. Este fenômeno afeta o equilíbrio do planeta; desempenha importante papel na regulação do clima global, mantendo o equilíbrio das chuvas e das temperaturas a partir das trocas gasosas.[14]

A utilização dos recursos das florestas tropicais de forma sustentável é ainda uma prática complexa.[5] Monitorar o desmatamento, na região Amazônica Brasileira, é uma tarefa que envolve muitos desafios, por isso, é necessário a utilização de sistemas de sensoriamento remoto, satélite de observação da Terra. Atualmente, o Brasil conta com dois satélites próprios capazes de gerar imagens dessa natureza: o satélite CBERS-4, desenvolvido em conjunto com a China em um programa de cooperação (China-Brazil Earth Research Satellite) em vigor há mais de 30 anos; e o Amazonia-1, primeiro satélite projetado, desenvolvido e integrado inteiramente no Brasil.

O Brasil conta com uma série de programas de monitoramento do desmatamento da região Amazônica Brasileira, sendo os mais conhecidos o PRODES e o DETER. Os sistemas que o Brasil utiliza apresenta algumas desvantagens, considerando, questões tecnológicas, como os tipos de sensores óticos utilizados, características físicas da radiação eletromagnética na faixa do espectro visível, por exemplo, o imageamento ótico é bloqueado pela presença de nuvens. Para evitar esses obstáculos, é necessário o uso de sistemas ativos de imageamento, que utilizam radar para emitir radiação na faixa do micro-ondas. O imageamento por satélite, a aquisição e o processamento de imagens de satélite com radar de abertura sintética (SAR) constituem-se em um dos instrumentos mais eficazes para a aquisição automatizada. O imageamento por SAR, além de superar obstáculos físicos presentes no sensoriamento ótico, tem outras capacidades úteis para o monitoramento da Amazônia Brasileira; permitem a aquisição automatizada, em seu estado inicial de imagens pré-processadas, a partir de modelos de aprendizagem de máquina aplicados, imagens em formato bruto, bem como a combinação dessas imagens com características previamente extraídas em técnicas de pré-processamento. Embora imagens SAR sejam eficazes, o uso ainda demanda etapas de processamento, de modo a tornar a imagem legível para o usuário. Uma dessas etapas é a fase de classificação de imagens, que consiste justamente em indicar se a imagem produzida retratou ou não o objeto desejado (por exemplo, se a imagem retrata uma área de desmatamento). Essa é uma etapa que consome bastante tempo e é ainda muito dependente de mão de obra humana, o que aumenta a janela de tempo entre o imageamento e a ação prática tomada com base nas informações dessa imagem.[227]

Desta forma, o grande diferencial deste estudo foi a utilização de três algoritmos, RNC, KNN, RF, de Inteligência Artificial, técnicas e ferramentas de GEO e SR, estratégia tecnológica que combinou essas áreas para classificar imagens de satélite da região Amazônica Brasileira, a partir, da classificação de objetos, conforme a definição dos rótulos, que identificaram áreas desmatadas. Por isso, a inovação deste estudo consistiu em classificar imagens que apresentam desafios específicos para análises,[40,41,42]aperfeiçoando a execução da classificação, com base em uma experiência pretérita, na observação dos rótulos, considerando e diferenciando as classes: *CORTE RASO, QUEIMADAS, MINERAÇÃO e ÁREAS DE PROTEÇÃO AMBIENTAL*, fatos que *justificam o potencial inovador desta Tese.*

1.1. Área de Estudo

As Figuras 1, 2, 3 apresentam a área de estudo.

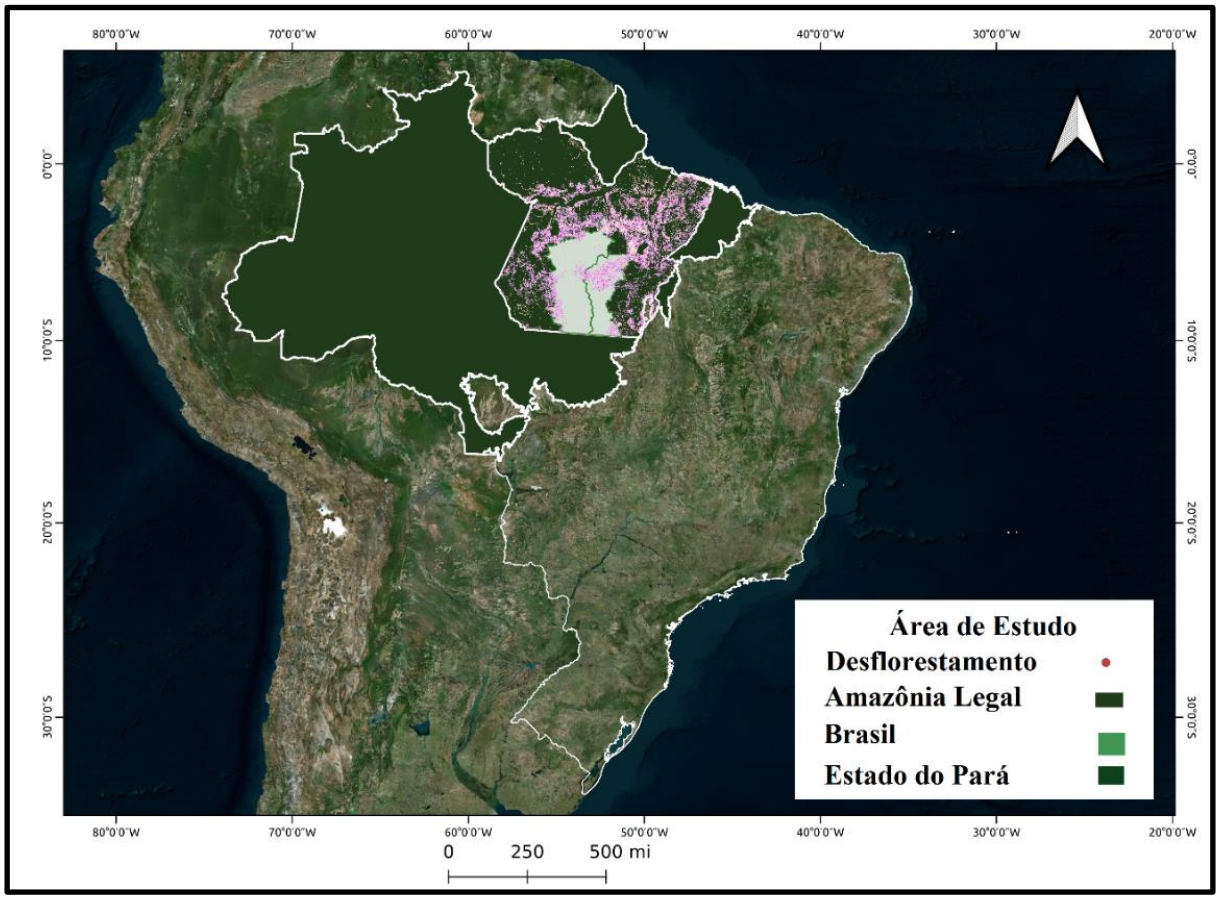

Figura 1- Área de estudo1, Brasil
Fonte: INPE

A porção brasileira da floresta Amazônica equivale a cerca de 4 milhões de Km^2. Encontra-se localizada na região denominada Amazônia Brasileira*(Amazônia Legal)* com território de 5.217.423 Km^2, equivalente a 61% do território Brasileiro.[18] A Amazônia Brasileira foi criada em 1953 para fins de planejamento político.[17] Compreende os estados do Acre, Amapá, Amazonas, Mato Grosso, Pará, Rondônia, Roraima e Tocantins e, parcialmente, o Maranhão[19]. A floresta Amazônica Brasileira representa cerca de 40% das florestas úmidas remanescentes no planeta,[20] área de maior biodiversidade do planeta, o maior banco genético do mundo. Possui 1/5 da reserva de água potável mundial.[21] A Amazônia Brasileira corresponde à área de atuação da Superintendência de Desenvolvimento da Amazônia (SUDAM) delimitada no Art. 2º da Lei Complementar número 124. A região Amazônica Brasileira possui 21.056.532 habitantes, ou seja, 12,4% da população Brasileira e a menor densidade demográfica do país (cerca de 4 habitantes por Km²). O Estado do Pará (Figura 2), localizado na região Amazônica Brasileira, apresenta área territorial com aproximadamente

1.245.870,798 Km² [22].

O Estado do Pará, localizado na região Amazônica Brasileira, foi um dos estados desta região mais afetado pelos planos e políticas governamentais, considerando as transformações sofridas na Amazônia Brasileira nas últimas décadas.

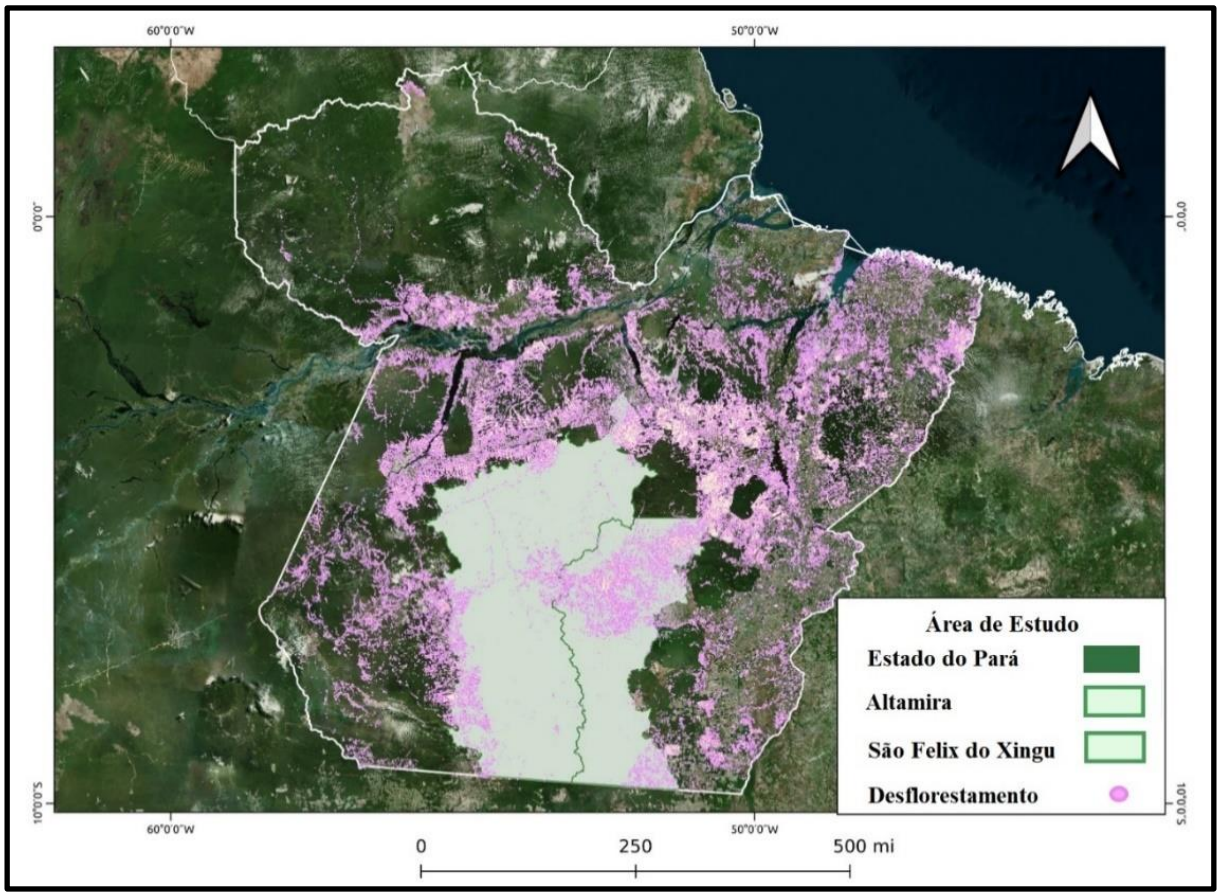

Figura 2 - Área de estudo 2, Pará
Fonte: INPE

Este espaço apresenta características ambientais peculiares, que influenciam na ocorrência de fenômenos executados neste ambiente, como no caso do monitoramento de desmatamento e focos de queimadas. Altamira e São Felix do Xingu *(área de estudo)* foram selecionados devido ao histórico de desmatamento observado; características ambientais, localização geográfica; presença de Área de Proteção Ambiental (APA) e unidades de conservação (UCs), terras indígenas, Agropecuaria industrial, mineração, áreas de desmatamento por queimadas, áreas de desmatamento por corte raso.

A Mesorregião do Sudeste Paraense possui grande quantidade de assentamentos.[24] Altamira e SFX (Figura 3) compartilham espaços protegidos, unidades de conservação (UCs), terras indígenas, assentamentos de reforma agrária e glebas públicas federais situados nestes municípios. Observa-se que 90,02% do território de Altamira e 74,42%do de São Félix está tomado por áreas protegidas.[25] O município de São Felix do Xingu engloba parte da Área de Proteção Ambiental (APA) Triunfo do Xingu. A área enfrenta um grande desafio por ter sido

criada em uma área com grande concentração populacional, grande pressão antrópica, território muito degradado e muitos conflitos fundiários. Incrementando a vulnerabilidade a desmatamentos na região, ameaçando a biodiversidade.[26]

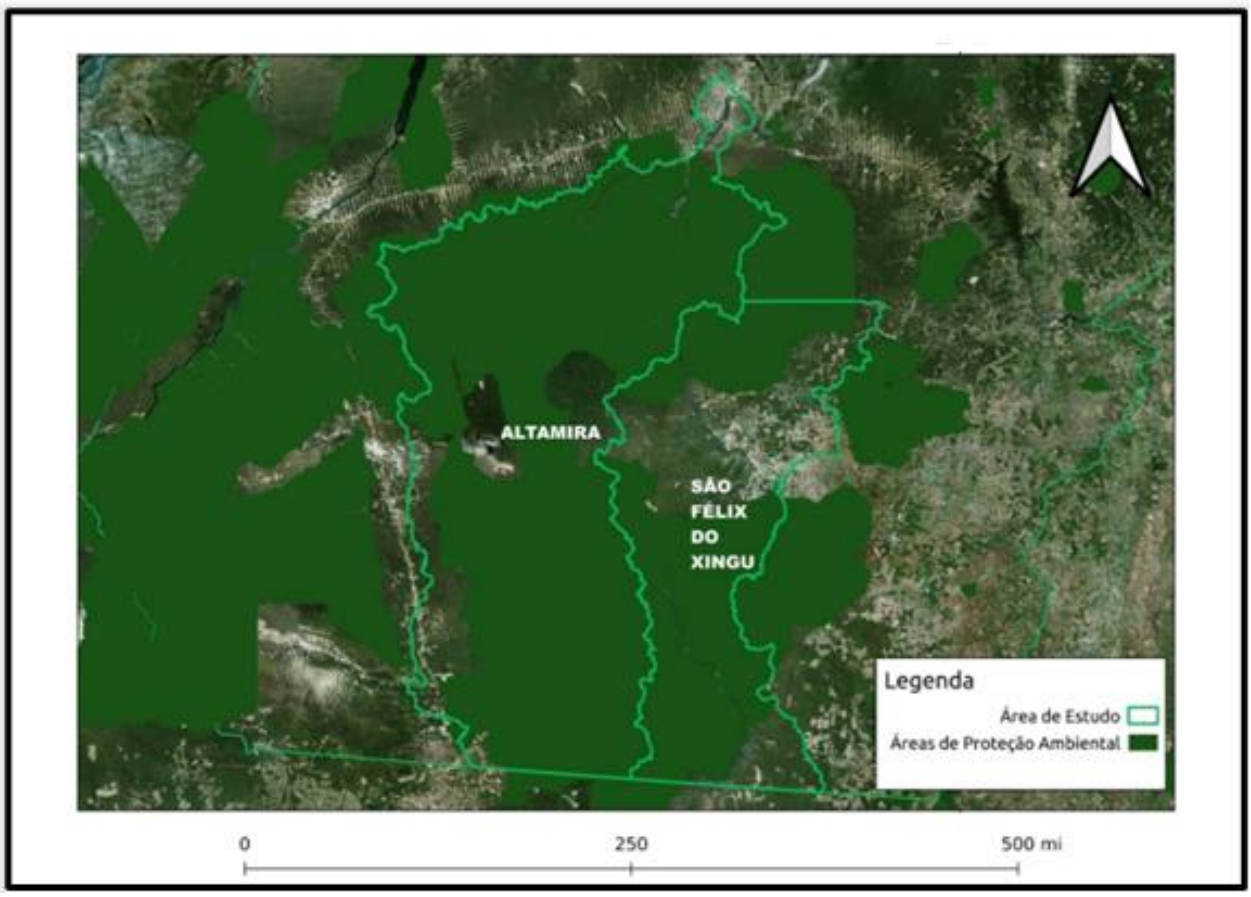

Figura 3 - Área de estudo 3, Altamira e SFX
Fonte: INPE

A Figura 3 destaca os dois municípios analisados. O município de São Félix do Xingu (SFX) está localizado nas coordenadas 06° 38' 42" S e 51° 59' 42", no Sudoeste do estado do Pará e na Microrregião de São Félix do Xingu, com uma área de 84.212,426 Km². A cidade de Altamira está situada na porção central do Estado do Pará, na margem esquerda do rio Xingu.[23]A FLONA de Altamira é uma Unidade de Conservação, área protegida pelo poder público federal, estadual e municipal, a qual engloba todos os espaços territoriais ambientais, águas jurisdicionais, com características naturais, legalmente instituídos pelo Poder Público, objetivando a conservação sobre um regime especial de administração, o qual se aplicam garantias e adequações de proteção.[27] A FLONA foi criada pelo decreto nº 2.483 de 2 de fevereiro de 1998[28,29] e possui 689.012 hectares pertencente ao estado do Pará, contendo hoje áreas de manejo florestal, que compreende a “administração da floresta para a obtenção de benefícios socioeconômicos e respeitando os mecanismos de sustentação do ecossistema”.[30]

1.2. Objetivo

1.2.1. Objetivo Geral

Analisar o desmatamento na Região Amazônica Brasileira utilizando Inteligência Artificial, Geoprocessamento e Sensoriamento Remoto, a partir da classificação de Imagens de Satélites.

1.2.2. Objetivos Específicos

- ✓ Monitorar dados de desflorestamento dos municipios de Altamira e São Felix do Xingu, estado do Pará, Região Amazônica Brasileira, Brasil, utilizando Inteligência Artificial (IA), GEO e SR, no período de 2001 a 2022;
- ✓ Utilizar IA, aprendizado de maquina, os algoritmos K-Vizinhos mais próximos (KNN), Floresta Aleatória (RF), e a Rede Neural Convolucional (RNC) para classificar imagens de satelites;
- ✓ Utilizar IA, aprendizado de maquina, os algoritmos K-Vizinhos mais próximos (KNN), Floresta Aleatória (RF), e a Rede Neural Convolucional (RNC) para gerar o aprendizado de parâmetros de identificação das classes de áreas de Florestas (considerando corte raso e queimadas), Áreas de mineração, áreas de proteção Ambiental;
- ✓ Integrar de Inteligencia Artificial, GEO e SR para analisar as relações entre os dados de desflorestamento de corte raso e queimadas; relacionando-os com áreas de proteção ambiental, atividades de mineração, decorrentes de ações antrópicas;
- ✓ Classificar imagens de satelites utilizando IA, GEO e SR, para identificar e analisar os resultados qualitativos de desflorestamento, a partir da interpretação visual das imagens processadas;
- ✓ Classificar imagens de satelites utilizando IA, GEO e SR, para identificar e analisar os resultados quantitativos de desflorestamento, a partir de métricas utilizadas.

2. Referencial Teórico

2.1. Desmatamento

O Brasil possui a maior floresta tropical do mundo, com uma área de aproximadamente cinco milhões de quilômetros quadrados. Esta floresta abriga a biodiversidade mais rica do planeta. No entanto, a taxa de desmatamento nas florestas tropicais brasileiras está entre as mais altas do mundo. [43]

De acordo com o Instituto Nacional de Pesquisas Espaciais (INPE) do Brasil, 4.688 quilômetros quadrados de floresta tropical foram removidos de agosto de 2019 a janeiro de 2020, um aumento de 113% em relação ao mesmo período do ano passado.[43] Em 2001, uma área de aproximadamente 837.000 Km^2 da Floresta Amazônia Brasileira original havia sido devastada.[253] A devastação se concentrou no Arco do Desmatamento, nas margens leste e sudeste da Amazônia Brasileira. No período que compreende os anos de 1998-2006,as taxas de desmatamento nesta região foram, em média, de 18.100 Km^2, tendo ocorrido no ano de 2004 o desmatamento de aproximadamente 27.400 Km^2 das áreas florestadas.[254]

O desmatamento pode ocorrer visando, por exemplo, a expansão das indústrias madeireira, agrícola e pecuária, sendo essa última, por meio da incorporação de pastos em fazendas de criação de gado, principal causa do desflorestamento na Floresta Amazônica Brasileira.[45]

O desmatamento no Brasil tem implicações globais. O país abriga uma parcela significativa da biodiversidade mundial e desempenha um papel fundamental na regulação do clima global. A perda de habitat resultante coloca em risco a diversidade de espécies e ameaça populações indígenas e comunidades tradicionais.

O monitoramento remoto usando imagens de satélite tem sido comumente usado para medir o desmatamento. Desde 1988, o INPE produz estimativas anuais das taxas de desflorestamento da Amazônia Brasileira. O INPE desenvolveu quatro sistemas de monitoramento da Amazônia Brasileira, cada um deles com uma função diferente: [46]

PRODES - Monitoramento da Floresta Amazônia Brasileira por Satélite. Utiliza imagens do satélite americano Landsat. Produz, desde 1988, estimativas anuais das taxas de desflorestamento da Amazônia Brasileira, divididas por Estado (Acre, Amapá, Amazonas, Goiás, Mato Grosso, Pará, Rondônia, Roraima e Tocantins). Cerca de 729 mil Km^2 foram desmatados no bioma Amazônia Brasileira, o que corresponde a 17% do referido bioma. Desse total, 300.000 Km^2 foram desmatados nos últimos 20 anos.

DETER - Detecção de Desmatamento em Tempo Real, é um levantamento rápido feito mensalmente pelo INPE desde maio de 2004, com dados dos satélites Terra e Aqua,

americanos, e CBERS. Tem como função enviar alertas de focos de desmatamento, para dar suporte aos órgãos de fiscalização e controle. DEGRAD – Mapeamento da Degradação Florestal na Amazônia Brasileira, mapeia áreas em processo de desmatamento onde a cobertura florestal ainda não foi totalmente removida. DETEX – Detecção de Exploração Seletiva, vigia áreas de manejo florestal, apontando se a exploração seletiva de madeira está de acordo com o que foi autorizado pelos órgãos ambientais.[46]

Neste contexto, esses sistemas foram desenvolvidos para apoiar a fiscalização e o controle do desmatamento e degradação florestal. Embora tenham sido concebidos para monitorar diferentes estágios do desmatamento, esses sistemas são complementares ao objetivo de mapear e monitorar o desmatamento na bacia Amazônica Brasileira. [47]

Os custos para manter sistemas de monitoramento de longo prazo são enormes e dependem de imagens de satélite que são influenciadas pela cobertura de nuvens.[47,48] Monitorar o desmatamento é um processo complexo. As investigações em torno deste tema são amplos e abrangem muitas áreas diferentes.[47]

O desmatamento ilegal se intensificou, nos últimos anos, na Amazônia brasileira, desta forma é urgente o uso de ferramentas capazes de responder rapidamente a essas atividades ilegais. Recentemente, os sistemas de vigilância baseados em UAV (VANT - Veículo Aéreo Não Tripulado) estão a emergir como uma solução promissora para monitorizar e prevenir o desmatamento.[49]

Os dados desses sistemas são uma alternativa viável para o planejamento de operações de prevenção ou combate ao desmatamento ilegal, pois podem abranger áreas remotas ou de difícil acesso[50]. Esses sistemas podem identificar a mineração, novos campos agrícolas ou outros tipos de desmatamento. Ao contrário das imagens de satélite tradicionais, os sistemas de vigilância de UAV (VANT - Veículo Aéreo Não Tripulado) podem obter imagens de altíssima resolução de áreas nebulosas.[45]

Um VANT pode voar automaticamente na área alvo e monitorar mudanças na cobertura florestal, detectando atividades de desmatamento, como extração de madeira ou mineração. Uma vez identificadas as atividades de desmatamento, sinais de alerta podem ser emitidos às autoridades responsáveis pela aplicação das leis ambientais na Amazônia brasileira.[45]

O monitoramento baseado em VANT pode ser mais eficiente do que a abordagem tradicional de monitoramento remoto, se as funções do VANT forem implementadas adequadamente e funcionarem com o nível de qualidade especificado. Contudo, os impactos

de um sistema de monitoramento baseado em VANT para prevenção do desmatamento, associados às qualidades do sistema, ainda são pouco explorados.

O modelo Tecnologia de Informação e Comunicação capturou os fatores que contribuem para a prevenção do desmatamento, incluindo medidas de qualidade do sistema para analisar quantitativamente os impactos de prevenção do desmatamento de um sistema de monitoramento baseado em VANT. O modelo baseou-se em um diagrama de circuito causal que formulou as relações entre medidas de qualidade do sistema, restrições operacionais, variáveis ambientais e indicadores-chave de desempenho associados à prevenção do desmatamento. [45] A análise de simulação esclarece os compromissos de design relacionados com as medidas de qualidade dos sistemas de vigilância baseados em VANT. Os resultados revelaram que voos adicionais de drones não são eficazes em termos de prevenção do desmatamento, quando este aumenta até um determinado número.

O desmatamento relacionado às dinâmicas de exploração por parte das indústrias madeireiras e agropecuárias, por meio de queimadas, extração ilegal de matéria e ocupações ilegais de terras públicas é um grave delito ambiental que contribui com degradação da floresta Amazônica Brasileira, compromete o equilibrio de ecossistemas, reflete em perturbações de ordem ambiental, social e econômica.

Considerando a agropecuária, a transformação da Floresta em pasto ou áreas agrícolas ocorre, principalmente, por meio das queimadas de natureza criminosa, as quais têm justamente esse objetivo. O motivo de ocorrência de queimadas com essa finalidade se dá pelo fato de o fogo ser método barato, acessível e prático para o manejo e preparo do solo das áreas escolhidas para realização de atividade agropecuária. [51,52]

As queimadas constantes acarretam em modificações da vegetação e do ciclo hídrico da Floresta Amazônica Brasileira, afetando ciclos de carbono e padrões de cheias e secas. Ademais, as queimadas podem ser, além de causa, consequência do desmatamento, pois um solo mais pobre, seco e desnutrido é mais tendencioso a queimar.[51,52.]

A pecuária cresceu rapidamente na Amazônia Brasileira estimulada por políticas e demanda de mercado. A produção de carne bovina em larga escala na Amazônia Brasileira é um fenômeno moderno. O acelerado crescimento da pecuária na região foi inicialmente promovido como estratégia de ocupação da região a partir do fim da década de 1960. Décadas depois, cresceu mais conectada ao mercado, mas ainda influenciada por subsídios. [53]

Os estímulos à ocupação incluíram abertura de estradas, incentivos fiscais, crédito rural subsidiado, projetos de colonização e reforma agrária. Entre 1974 e 2019, o rebanho bovino nos municípios da Amazônia Brasileira cresceu quase dez vezes e atingiu 89 milhões

de cabeças. Neste período, o rebanho da região saiu de 9% para 42% do total do Brasil. [53]

Além do custo de desmatar cada hectare ser menor do que o de reformar os pastos, o desmatamento de terras públicas pode resultar em ganhos de subsídios provenientes de regularização fundiária. Finalmente, em 2018, havia 12 milhões de hectares de florestas passíveis de desmatamento legal de acordo com o Código Florestal [55,53]

A perda florestal é a principal fonte de emissões de carbono no Brasil. No entanto, tem havido variações significativas no ritmo com que os governos federal e estaduais têm prosseguido a operacionalização interna de políticas de redução de emissões provenientes do desmatamento e da degradação florestal em vários níveis de governação. [56,57]

2.2. Desmatamento e Legislação

Não é possível desvincular “legislação” de “meio ambiente”, ambos devem andar juntos, nos ditames do preceito normativo vigente no artigo 225 da Constituição Federativa da República do Brasil. O direito ao meio ambiente ecologicamente equilibrado é de todos, é fundamental que o Poder Público salvaguarde sua defesa e preservação.[51]

Com o aumento substancial de desmatamento na Amazônia Brasileira a partir de 2019, governos federal e estaduais na região passaram a defender a regularização fundiária. Porém, ao contrário do que preconiza o senso comum.[55]Estima-se que uma área equivalente a 29% da Amazônia Brasileira (1,43 milhão de Km^2), atualmente sem informação de destinação fundiária, possa ser alvo da continuidade do processo de grilagem e desmatamento, que gera conflitos e afasta investimentos de qualidade para o desenvolvimento na região. Na lei federal e no estado do Pará, há excessões solicitando esse comprometimento antes da titulação em alguns casos. O poder público deve considerar as prioridades legais para reconhecimento de demandas territoriais de povos indígenas, comunidades quilombolas e tradicionais, bem como a criação de áreas protegidas e a titulação de imóveis para agricultura familiar. No entanto, na maioria dos estados não há exigência de consulta prévia à titulação sobre o interesse de outros órgãos na área em avaliação, como Fundação Nacional do Indio e órgãos ambientais.[55] [45]O desmatamento é considerado um dos principais fatores de impacto de mudança climática, estimar a emissão de gás CO_2 devido ao desmatamento é essencial. As queimadas também provocam a emissão de outros gases de efeito estufa, como o metano e o óxido nitroso. [45]

2.3. Desmatamento na Floresta Amazônica Brasileira

Embora as taxas e as causas do desmatamento ocorrem de acordo com cada região, a perda de florestas é uma preocupação compartilhada em diferentes continentes. As florestas desempenham um papel crucial na absorção do dióxido de carbono (CO_2) da atmosfera. As florestas abrigam uma diversidade impressionante de espécies.

Desmatamento é a remoção total da cobertura florestal, independentemente do uso destinado para a área desmatada. O desmatamento pode ocorrer por corte raso, quando a cobertura florestal é abruptamente removida em uma única intervenção, ou pode ser o resultado de eventos de degradação recursivos que levam ao colapso completo da estrutura florestal da vegetação. [70]

Desmatamento com vegetação são áreas em que há evidência de desmatamento, mas a área desmatada se encontra com sinais de uma cobertura vegetal. São casos em que há um lapso de tempo entre a ocorrência do corte raso e a sua detecção, ocasionado pela cobertura de nuvens entre um evento e outro, ou o resultado final da degradação recursiva. Mineração: desmatamento causado por atividade de extração mineral. Predomina nesta classe atividades de garimpo artesanal.[70]

O desmatamento é um problema global. A retirada de floresta afeta várias regiões do mundo, refletindo em consequências graves para o meio ambiente, a biodiversidade e o clima global. O desmatamento refere-se ao processo de remoção ou destruição de florestas. Ocorre quando as árvores são cortadas ou queimadas. O desmatamento é um tema de preocupação global, devido às consequências, que podem afetar a biodiversidade, o clima e as comunidades em escala global.

As principais causas de desmatamento incluem a expansão da agricultura de subsistência, a extração madeireira insustentável, a produção de carvão vegetal, impulsionado pela indústria madeireira ilegal, a mineração; a expansão agrícola de pequena escala e a exploração de recursos naturais, como petróleo e minerais, o desenvolvimento de infraestrutura, como estradas e áreas urbanas.

O desmatamento na Amazônia Brasileira é um tema de preocupação global devido à importância desse bioma para a biodiversidade, o clima e as comunidades. O desmatamento na Amazônia Brasileira é impulsionado por várias causas, incluindo: expansão agrícola: a conversão de florestas em áreas agrícolas é uma das principais causas de desmatamento. Grandes áreas de floresta são frequentemente derrubadas para abrir espaço para plantações de culturas comerciais. O crescimento de áreas urbanas e a construção de infraestrutura. [67]

A conversão de áreas florestais em terras para agricultura, principalmente para a criação de gado e o cultivo de *commodities* como a soja, é uma das principais causas do

desmatamento na região. A demanda global por produtos agrícolas tem contribuído para a expansão das fronteiras agrícolas na Amazônia Brasileira. A exploração madeireira ilegal e não sustentável é outra causa importante do desmatamento na região.[67]

A extração ilegal de madeira, associada a atividades criminosas, contribui para a destruição de grandes áreas de floresta. A construção de estradas, usinas hidrelétricas, barragens e projetos de mineração também contribuem para o desmatamento na Amazônia Brasileira. A abertura dessas vias de acesso pode levar à invasão de áreas florestais por colonos, especulação de terras e outras atividades predatórias. [67]

As causas do desmatamento variam de acordo com peculiaridades de cada a região geográfica: A extração de madeira para uso comercial e a exploração de minerais. A construção de estradas, barragens e outros projetos de infraestrutura. As mudanças climáticas. Aumento na temperatura, secas prolongadas e eventos climáticos extremos podem enfraquecer as florestas, tornando-as mais suscetíveis a incêndios e doenças, além de dificultar a regeneração natural. [67]

Em algumas regiões, os incêndios florestais contribuem com o desmatamento. O desmatamento tem várias consequências negativas ao meio ambiente. A remoção de grandes áreas de floresta altera os padrões de chuva, aumenta a temperatura local, contribui para fenômenos extremos, como secas, enchentes; favorece a perda de serviços ecossistêmicos.[45]

O carbono armazenado é liberado na atmosfera na forma de CO_2, contribuindo para o aquecimento global e as mudanças climáticas, contribui para o aumento das emissões de gases de efeito estufa; comunidades indígenas e locais dependem das florestas para sua subsistência e identidade cultural, esse processo afeta diretamente os meios de vida tradicionais dessas comunidades. [45]

As florestas atuam como sumidouros de carbono, absorvendo o CO_2 da atmosfera; as florestas auxiliam na regulação dos padrões climáticos, influenciando a circulação de água e ar. As florestas fornecem uma ampla gama de serviços ecossistêmicos essenciais para o bem-estar humano. [45]

As consequências do desmatamento na Amazônia Brasileira são significativas: Perda de biodiversidade: A Amazônia Brasileira é uma das regiões mais biodiversas do mundo, abrigando uma vasta quantidade de espécies de plantas, animais e micro-organismos. O desmatamento resulta na perda de habitat e na diminuição da diversidade biológica, colocando em risco inúmeras espécies, incluindo aquelas endêmicas e ameaçadas de extinção.

As florestas tropicais, a Amazônia Brasileira, desempenham um papel crucial na regulação do clima global. O desmatamento libera grandes quantidades de carbono

armazenado nas árvores, contribuindo para o aumento das emissões de gases de efeito estufa e o aquecimento global.

O desmatamento na Amazônia brasileira tem implicações ambientais, climáticas e sociais significativas. As florestas desempenham um papel crucial na absorção de carbono e na regulação do clima. A liberação de grandes quantidades de carbono decorrente do desmatamento contribui para as emissões de gases de efeito estufa e o aquecimento global.[45]

O desmatamento desencadeia processos de degradação do solo, tornando-o menos fértil e menos capaz de sustentar a vida vegetal e animal, e aumenta o risco de desertificação. A remoção das florestas aumenta a quantidade de sedimentos e poluentes que entram nos rios e lagos, afetando negativamente a qualidade da água e prejudicando os ecossistemas aquáticos. [45]

Para que se aumente a produtividade sem o desmate, é basilar pensar em investimento em infraestrutura e serviços adequados nas regiões com maior potencial produtivo e de retorno social e econômico, com o devido planejamento, e na expansão de assistência técnica a essas regiões.[45] Planejar adequadamente como se dará o investimento em infraestrutura é essencial.

A usina hidrelétrica de Belo Monte, na região Amazônica Brasileira do Pará intensificou focos de desmatamentos e contribuiu para o aumento de pobreza da região.[71]Neste sentido, pode-se falar do apoio à agricultura familiar, Lei nº 11.326 de 24 de julho de 2006, é uma forma de agricultura que apresenta melhores condições de sustentabilidade, ao incorporar estratégias de equilíbrio entre os parâmetros econômicos, sociais e ambientais.[45]

A maior parte da alimentação dos brasileiros vem da agricultura familiar, sendo esta fundamental na manutenção da segurança alimentar da nação; a criação de ocupações produtivas, o valor por hectare e a contribuição com a alimentação do país é superior às contribuições do agronegócio; a sustentabilidade neste sistema produtivo denota uma característica diferenciadora, considerando os impactos positivos ao ambiente, pelo reaproveitamento de resíduos considerando à fertilidade do solo e as oportunidades criadas no que tange a geração de renda para as famílias agricultoras.[45]

2.4. Geoprocessamento e Sensoriamento Remoto

O Sensoriamento Remoto e o Geoprocessamento foram utilizados para compreender o comportamento do desmatamento na região Amazônica Brasileira. As imagens dos sensores e técnicas de Geoprocessamento são imprescindíveis para analisar áreas mais remotas da região Amazônica Brasileira.

2.4.1. Geoprocessamento

O Geoprocessamento é o conjunto de técnicas e métodos teóricos e computacionais relacionados com a coleta, entrada, armazenamento, tratamento e processamento de dados. Objetiva gerar novos dados e ou informações espaciais georreferenciadas.[72] Excelente ferramenta para o estudo de análises ambientais, consiste no processamento de dados geoespaciais, produzindo informações a partir de dados de entrada. O monitoramento de áreas remotas tem sido impulsionado pelo avanço do Sensoriamento Remoto (SR), uma técnica que utiliza de sensores para obter informações sobre o objeto de estudo à distância.[88]

O Geoprocessamento é o conjunto de técnicas e métodos teóricos e computacionais relacionados com a coleta, entrada, armazenamento, tratamento e processamento de dados. Objetiva gerar novos dados e ou informações espaciais georreferenciadas.[72] Excelente ferramenta para o estudo de análises ambientais.

Para uma aplicação com geoprocessamento uma Rede Neural Convolucional (RNC) treinada por Aprendizado Supervisionado torna-se bastante eficaz, afinal o geoprocessamento consiste no processamento de dados geoespaciais, produzindo informações a partir de dados de entrada. Algumas vantagens que podem ser destacadas a favor das RNC, na predição e classificação de imagens de vegetação agrícola, são:[73,133,224]Capacidade de atingir alto desempenho em tarefas visuais complexas; capacidade de aprender automaticamente um grande número de filtros; muito flexível, permitindo a solução de problemas de diferentes segmentos; reconhecimento de imagens com altíssimas taxas de acerto; possuí sucesso em experimentos envolvendo processamento de vídeo, voz e linguagem natural.

Sistemas de Informações Geográficas (SIGs) são sistemas que tem sido amplamente utilizados no planejamento ambiental. Permitem incorporar e analisar cenários com grande variedade de informações, de forma integrada e otimizada. Conjunto de técnicas empregadas na integração e análise de dados. Dados provenientes de imagens fornecidas por satélites, mapas, cartas climatológicas, censos. Auxiliado porcomputadores para adquirir, armazenar, analisar e exibir dados geográficos.[75,76]

Um sistema composto por softwares e hardwares que estão submetidos a uma organização de pessoas interligadas para um mesmo fim. Os SIGs Utilizam dados georreferenciados para realizar a coleta, o armazenamento, a edição, o processamento, a análise e a disponibilização de dados e informações. Estes sistemas visam planejar e monitorar questões ligadas ao espaçofísico geográfico através de produtos gerados pelo sistema. Esses produtos são arquivos digitais contendo mapas, gráficos tabelas e relatórios convencionais.[72]

SIG é um software capaz de identificar os atributos associados a suas informações georreferenciadas.[77,78] Capaz de lidar um dados geoespaciais, o SIG é utilizado em diversas áreas de estudo como meteorologia, agricultura, hidrologia, saúde pública, economia.[79,80,81]

O SIG tem dois tipos de dados principais, sendo eles objetos vetorizados ou rasterizados.[82] O principal tipo de arquivo de um SIG é o Shapefile, o qual possui menor volume de dados e melhor resolução espacial se compararmos com dados raster.[77] Para combinar o SIG com Sensoriamento Remoto é necessário integrar ambos os dados de vetor e raster[83] utilizando técnicas de conversão e processamento de imagens[84]

2.4.2. Sensoriamento Remoto

O Sensoriamento Remoto (SR) iniciou nos anos 60.[85]As atividades de SR não se limitam à superfície terrestre, tiveram início a partir da necessidade de se obter informações remotas de planetas. A análise das imagens de sensoriamento remoto e as atividades de interpretação dessas imagens repousam no processo de interpretação de cores, padrões e texturas. Os olhos são o derradeiro sensor contra o qual os demais são calibrados. O monitoramento de áreas remotas tem sido impulsionado pelo avanço do Sensoriamento Remoto (SR), uma técnica que utiliza de sensores para obter informações sobre o objeto de estudo à distância.[88]

As técnicas e ferramentas do SR são muito eficientes, principalmente com o advento de soluções de fácil acesso e código aberto.[110] O progresso na tecnologia do SR e a observação da Terra destacam a importância dos métodos automatizados/semiautomatizados.[171] Esse progresso no SR possibilitou a classificação de cenas usando imagens de satélite e tem sido responsável no desenvolvimento de novas abordagens, especialmente em métodos de aprendizado de máquina.[111,112]

O uso de imagens SAR de polarização dupla se mostra ainda mais eficaz quando se trata da detecção do desmatamento recente, uma vez que os valores de banda da vegetação se diferem do desmatamento recente.[90]Isso junto ao monitoramento recorrente que esteja dentro de uma faixa temporal que permita a correlação das imagens, de um a onze dias[91]é possível estabelecer o monitoramento eficaz da região. A disponibilidade de dados abertos de imagens de satélite impulsionou o interesse de estudos de SR utilizando imagens SAR.

Isso possibilita o desenvolvimento de estudos na área sem a necessidade de grandes investimentos.[92]

Na área de SR, os algoritmos baseados em Convolutional Neural Networks (CNN) são amplamente empregados e testados juntos a algoritmos baseados em Support Vector Machine (SVM). Estudos com diferentes abordagens, algoritmos, para a identificação de desmatamentos a partir de imagens SAR.[93,94,95] Esses algoritmos costumam produzir resultados excepcionais, alcançando uma acurácia acima de 90% com CNNs de arquitetura U-Net. Uma prática comum em muitos projetos é combinar imagens SAR com imagens multiespectrais.

O desenvolvimento de satélites se encontram na categoria de programas voltados para Observação da Terra (Earth Observation - EO). No contexto brasileiro destacam-se os programas China-Brazil Earth Resources Satellite (CBERS) e o Amazônia-1.[96,97]Os dados provenientes dos satélites são geralmente multiespectrais, hiperespectrais, Lidar ou de SAR.[98]Essas imagens são amplamente utilizadas para a detecção de desmatamento, seja de forma isolada[99,100]ou por meio de “fusões” entre as imagens.[101] O que varia é o método de análise que o operador utilizará para extrair informações relevantes dos dados.

Segundo dados de um relatório da Euroconsul, durante a próxima década, estima-se que cerca de 990 satélites sejam lançados todos os anos, provavelmente, em 2028, existirá cerca de 15.000 equipamentos em volta da órbita terrestre.[102]

Os satélites podem ser classificados de diversas maneiras, em relação ao tipo de sensor, pode ser ativo ou passivo.[103] O LANDSAT-8[77] é um satélite de sensor passivo que capta imagens multiespectrais incluindo o espectro visível e infravermelho, o Sentinel-1a[104] é um satélite de sensor ativo por emitir um sinal de propagação de radar de abertura sintético, captando o espectro do Banda C. As informações mais importante para SR são as resoluções espacial, temporal e espectral das imagens de satélite. As órbitas influenciam no alcance de informações do satélite.[103] Satélites como o Sentinel-1 e ALOS PALSAR[105] fornecem, de forma gratuita, bases de dados de imagens SAR, contribuindo significativamente para a viabilidade e acessibilidade desses recursos. O satélite Sentinel-2B possui sensores multiespectrais de alta resolução espacial e temporal com a finalidade de realizar o monitoramento da vegetação, áreas costeiras.[133]

Synthetic Aperture Radar (SAR), Radar de Abertura Sintética, consiste em uma tecnologia muito utilizada para Sensoriamento Remoto, que é capaz de captar imagens em alta resolução da terra por meio da emissão de ondas de radar.[106] A disponibilização de imagens ocorre de maneira gratuita de alguns satélites SAR. A principal plataforma é a base de dados da ASF, que conta com datasets dos satélites Sentinel-1, ALOS PALSAR. Uma das vantagens na utilização dessa plataforma é a conectividade com linguagem Python,

permitindo a automatização do processo de busca e download das imagens.[105]

Os satélites passam a ter a característica de sensor ativo, uma vez que opera emitindo um pulso eletromagnético que será refletido pela superfície da terra em seguida captada pelo satélite, permitindo dessa forma a coleta de informação. Uma das principais vantagens ao se utilizar imagens SAR, é o fato de que as imagens captadas não sofrem interferência de nuvens. Dessa forma permite a realização de coleta de dados de regiões em períodos chuvosos.[107]

Diferentes formas de SR são passíveis de aplicação na Amazônia Brasileira, como o uso de drones[108]e o uso de aeronaves utilizando de escaneamento a laser.[109] Essas tecnologias possibilitam o monitoramento de áreas de difícil acesso. No entanto, possuem uma área de alcance limitada se compararmos com SR via satélite, sendo mais bem aplicadas em áreas de estudo específicas e previamente definidas.[42]

O avanço nas técnicas de sensoriamento remoto (SR) e o sistema de informações geográficas (SIG) fornecem ferramentas para o apoio no estudo da dinâmica ambiental. [174] No entanto, a crescente disponibilidade de conjuntos de dados temporais arquivados, junto a necessidade de métodos para analisar quantidades gigantescas de arquivos são desafios para o cenário do SR, mas também uma solução.[118,175] O desenvolvimento da tecnologia de satélites proporciona armazenamento de dados em domínio público para fins de pesquisa.[176]O Sentinel 2 (S-2) é parte do Programa de observação da Terra “Copernicus” e registra, com imagens ópticas em alta resolução espacial, informações sobre corpos terrestre e aquático.[112]

As técnicas e ferramentas do SR são muito eficientes, principalmente com o advento de soluções de fácil acesso e código aberto.[110,111] O progresso na tecnologia do SR possibilitou a classificação de cenas usando imagens de satélite e tem sido responsável no desenvolvimento de novas abordagens, especialmente em métodos de aprendizado de máquina.[112] Estudos que comparam algoritmos de aprendizado de máquina devem fazê-lo de maneira consistente, passar por correções geométricas e/ou radiométricas e, em boa parte, atmosférica.[110,113]

O termo foco de calor é utilizado para o registro da ocorrência do fogo na superfície terrestre, obtido por meio das técnicas de SR.[119] A importância da detecção das queimadas transcende a ocorrência dos focos de calor, uma vez que o SR orbital constitui um importante sistema de monitoramento ambiental, sobretudo quando associado ao mapeamento de incêndios florestais e na identificação de áreas desmatadas.[120] Quando o fogo atinge grande proporção, e não está sob o controle humano, há a ocorrência de um incêndio.[121] O incêndio florestal atinge as espécies vegetativas de forma geral.[122,123]

2.5. Inteligência Artificial (IA)

A inteligência artificial (IA), área da ciência da computação, utiliza sistemas e algoritmos capazes de realizar tarefas que simulem a inteligência humana. Sistemas, modelos, algoritmos projetados para simular a capacidade de aprender, raciocinar, tomar decisões e resolver problemas. A IA baseada em aprendizado de máquina utiliza algoritmos para aprender padrões e tomar decisões com base em dados. A IA é um campo multidisciplinar. As aplicações são inúmeras, aprendizagem e percepção até tarefas específicas como demonstração de teoremas matemáticos e condução autônoma de carros.[111,132]

O conceito de inteligência artificial surgiu em meados do século passado. Na década de 50, um grupo de cientistas debateu sobre a possibilidade de as máquinas desenvolverem atividades humanas. A inteligência artificial era um tema que era quase restrito a produções de ficção científica.[133] Em 1950 foi estabelecida a associação entre computação e inteligência, através de um artigo acadêmico nomeado de computação de máquinas e inteligência, escrito por Alan Mathison Turing. No início, a IA causou muita polêmica, pois muitas pessoas acreditavam que o objetivo da IA era desenvolver máquinas que eventualmente substituiriam os humanos. A interação entre humanos e robôs acabará se tornando tão natural quanto a interação entre pessoas.[134]

A Inteligência Artificial busca construir mecanismos, físicos ou digitais, que simulem a capacidade humana de pensar e de tomar decisões. Para o criador do termo, John McCarthy (1962) a definição de Inteligência Artificial é “a ciência e engenharia de produzir sistemas, inteligentes”. É um campo da ciência, cujo propósito é estudar, desenvolver e empregar máquinas para realizarem atividades humanas de maneira autônoma. Esses sistemas se alimentam basicamente de dados, aprendem com estes e se ajustam a cada entrada de novos dados. A IA pode absorver grandes quantidades de informação e deduzir resultados sem intervenção humana, otimiza processos de maneira revolucionária.[133]

A Inteligência Artificial se propõe a elaborar dispositivos que simulem a capacidade humana de raciocinar, perceber variáveis, tomar decisões e resolver problemas, a capacidade de ser inteligente. A IA é um conceito que pertence à computação e consiste na capacidade que máquinas têm de interpretar dados externos, aprender a partir dessa interpretação e utilizar o aprendizado para resolver tarefas específicas e atingir objetivos determinados. É a capacidade de dispositivos eletrônicos funcionar similar ao pensamento humano.

O funcionamento da inteligência artificial ocorre quando um sistema, a partir de comandos e símbolos computacionais, começa a aprender e analisar grandes volumes de dados. Mais do que alimentação é fundamental importância de bons dados para os sistemas de IA, nutrição de qualidade. Em termos mais simples, a Inteligência Artificial refere-se a

sistemas ou máquinas que mimetizam a inteligência humana para executar tarefas e podem se aprimorar iterativamente com base nas informações que coletam.

A IA restrita é encontrada principalmente em computadores, com sistemas inteligentes que aprenderam a realizar tarefas sem necessariamente serem programados para tal fim. É a inteligência artificial que está presente nos assistentes virtuais e em recomendações de produtos com base na preferência do consumidor. A IA geral está mais próxima à capacidade humana de adaptar conhecimentos; mais flexível e, diferente da IA restrita, pode aprender a executar tarefas diferentes, desde criar uma planilha até processar grandes quantidades de dados, com base na experiência acumulada.[134]

A IA é um tipo de inteligência que os humanos produzem para dar às máquinas algum tipo de habilidade que imita a inteligência humana, ramo da ciência da computação que estuda o desenvolvimento de máquinas inteligentes que agem e reagem de maneiras bem semelhantes às dos seres vivos. Percebe-se como IA avançou ao longo dos anos, o sistema chamado de Google Neural MachineTranslation (GNMT) impulsionou este avanço. Seguindo uma estrutura de aprendizagem que aprende com milhões de exemplos linguísticos, a qualidade das traduções melhorou. No celular, existe uma série de recursos onde há presença da inteligência artificial. Com a Inteligência artificial, as empresas são capazes de coletar e armazenar dados dos seus clientes a fim de que os sistemas façam análises completas de comportamento e hábitos. Isso facilita as estratégias de marketing, com uma abordagem segmentada e personalizada. A inteligência artificial envolve praticamente todas as partes do seu dia. Embora seja inicialmente possível assumir que tecnologias como alto-falantes inteligentes e assistentes digitais sejam sua extensão. [133]

A IA tornou-se rapidamente uma tecnologia de uso geral, repercutindo em diversos setores, como transportes, saúde, serviços financeiros e muito mais. Na era moderna, a compreensão da IA e suas possibilidades para todos é essencial. Um exemplo “mais falado”, no momento é o ChatGPT, modelo de linguagem baseado em deep learning (aprendizagem profunda), um “braço” da inteligência artificial. Na prática, a plataforma utiliza um algoritmo baseado em redes neurais que permitem estabelecer uma conversa com o usuário a partir do processamento de um imenso volume de dados. O ChatGPT se apoia em milhares de exemplos de linguagem humana. A ferramenta foi desenvolvida em 2019 pela empresa norte-americana Open AI.[133] Na era moderna, a compreensão da IA e suas possibilidades para uma empresa é essencial. A Inteligência artificial também é observada em serviços como do iFood. O iFood usa uma iniciativa que reduz os impactos ambientais ao dispensar o uso de veículos movidos a combustíveis fósseis, usa drones. Integra interesses dos negócios à preocupação com a sustentabilidade, aplicando a inteligência artificial também em mecanismos de redução de impacto ambiental. Ao receber o chamado do aplicativo, o robô faz a rota de forma

inteiramente autônoma até o restaurante, coleta o pedido e se dirige até um mensageiro que o levará ao ponto final: o iFood hub, destino estrategicamente localizado para distribuição do pedido.[133] Aprendizado de máquina, por sua vez, é uma subárea do campo da inteligência artificial (IA) que busca desenvolver a capacidade de uma máquina, autonomamente, aperfeiçoar a execução de uma determinada atividade (a classificação de uma imagem), com base em uma experiência pretérita.

[135]O uso das expressões: “Inteligência Artificial Sustentável”, “Inteligência Artificial para a sustentabilidade” e “Sustentabilidade da Inteligência Artificial” foram apresentadas por Wynsberghe em 2021. A preocupação em se ter um mundo mais ecológico tem impulsionado o aumento de pesquisas em computação aplicada ao meio ambiente.[136]A mineração de dados e big data pode ser usado para selecionar locais geológicos de CO_2.[137]Entender os efeitos produzidos por um processo de Aprendizado de Máquina (AM) na ação climática; Priorizar ações que alinhem os estudos de AM às estratégias climáticas[138] como um estudo preliminar do uso de IA para prever o preço do carbono.[139]A busca por projeções do clima pode ajudar a ter políticas públicas mais adequadas para a sociedade. [140]

2.5.1. Aprendizado de Máquina (AM)

O objetivo do Aprendizado de Máquina[141]é construir modelos estatísticos para prever e/ou classificar algo de interesse. Na prática, existem dois tipos de algoritmos, os modelos supervisionados e os não supervisionados. Neste estudo, propomos usar diferentes algoritmos baseados em modelos supervisionados para treinar imagens de satélites da região Amazônica Brasileira. Em particular, para determinar o melhor algoritmo de aprendizagem de máquina para o objetivo proposto, testaram-se três alternativas complementares: K-Nearest Neighbours (KNN), Redes Neurais convolucionais (RNC) e Florestas Aleatórias (RF).

Aprendizado de máquina, subárea da IA, objetiva desenvolver a capacidade de uma máquina aperfeiçoar a classificação de uma imagem, dentre outros objetivos. O Aprendizado de Máquina (AM) é a área que se dedica a implementar algoritmos que permitam a análise de dados de forma automática, sendo as melhorias e as técnicas para construí-lo derivadas do conhecimento prévio, da representação dos dados e do feedback da aprendizagem[111,132]

O objetivo do aprendizado de máquina concentra-se no estudo dos aspectos computacionais inerentes ao fenômeno do aprendizado, seja este observado em máquinas naturais ou artificiais. Um dos seus objetivos principais é o de propiciar a construção de sistemas capazes de adquirir e integrar, por conta própria, conhecimento acerca do domínio (classe de problemas) em que atuam, de modo a melhorarem progressivamente seu desempenho em relação ao cumprimento de seus objetivos. Nesse sentido, o aprendizado de

máquina apresenta-se como uma metodologia alternativa a abordagens tradicionais voltadas para a especificação manual (de “tentativa-e-erro”) de tais sistemas.[143]

KNN, RF, RNC são algoritmos que tem como base os conceitos de Aprendizado de máquina, termo utilizado para definir algoritmos que extraem informação a partir de um conjunto de dados (amostras). Para criar as amostras capazes de identificar os padrões das classes, e dessa forma “ensinar” os algoritmos reconhecem padrões em imagem.[144] A aplicação do aprendizado de máquina tem se tornado cada vez mais comum em tarefas que envolvam a extração de informações relevantes de um grande volume de dados e cuja solução exata não é conhecida, fato que foi impulsionado pelo crescimento exponencial do Big Data. O aprendizado de máquina em sua essência pode ser empregado de diferentes formas, levando em consideração a quantidade e o tipo de supervisão que recebem durante a etapa de treinamento de um determinado modelo.

O aprendizado supervisionado é o tipo de aprendizado mais comum quando discutimos aprendizado de máquina e consiste em dispor de exemplos de entrada e de saída dos dados desejados, com o objetivo de reconhecer padrões nos dados de entradas, também conhecidos como atributos ou preditores, que levam à variável de saída, também conhecida como rótulo ou alvo.[145] Uma das aplicações mais comuns do aprendizado supervisionado é a tarefa de classificação, que consiste no processo de encontrar um modelo que consegue distinguir classes de dados a partir dos previsores de entrada, dessa forma é possível identificar a classe de um objeto que ainda não é conhecido.

O aprendizado semi-supervisionado se utiliza tanto de dados rotulados quanto de dados não rotulados para realizar as suas predições. Esse método utiliza os dados rotulados para criar modelos de classificação, utilizando dos dados não rotulados para ajustar as fronteiras entre as classes.[145]

Um exemplo muito conhecido de um algoritmo de classificação que se utiliza deste tipo de aprendizado é o Google Fotos. O algoritmo reconhece que uma única pessoa aparece em mais de uma imagem através de uma tarefa de clusterização não supervisionada, e com o auxílio do usuário que irá rotular uma das imagens com a identificação da pessoa, possibilitando que um algoritmo de classificação supervisionado classifique as demais fotos.[146]

2.5.2. Floresta Aleatória (RF)

Dentre os modelos de aprendizagem supervisionados, destacam-se a árvore de decisão, Floresta aleatória (Random Forrest - RF). [132] Random Forest (RF), mecanismo que agrega de forma aleatória várias árvores com versatilidade para lidar com tarefas de classificação e regressão supervisionada.[147] RF possuí característica de “dividir para conquistar”, a técnica apresenta um algoritmo mais poderoso do que comparado somente a uma árvore de decisão, são menos sensíveis a ruídos.[148]

O algoritmo RF é considerado um método do tipo ensemble, cujo intuito é combinar as predições de vários modelos diferentes, de forma a construir um mecanismo de predição mais robusto. Cada um dos modelos é uma árvore de decisão construída a partir da seleção de um conjunto aleatório de amostras, definido utilizando a técnica de bootstrap, que permite a escolha de instâncias repetidas. Na construção de cada árvore de decisão os melhores pontos de split são encontrados a partir da avaliação de um subconjunto aleatório dos atributos de entrada. Dessa maneira, realizando a média das predições de cada árvore, esse modelo consegue contornar os problemas de alta variância e overfitting, comuns de ocorrer, em uma simples árvore de decisão.[146,149]

As árvores de decisão são algoritmos de aprendizado supervisionado extremamente versáteis, que podem executar diferentes tarefas, como classificação, regressão e tarefas com múltiplas saídas. Possuem a capacidade de representar a relação entre os atributos e os alvos por meio de um conjunto de regras arranjadas em forma de árvore. Durante o treinamento, cada regra divide os dados em parcelas menores até que os conjuntos gerados sejam completamente puros ou que alguma outra condição de parada seja satisfeita.[145]

Com o aumento da necessidade de técnicas de classificação mais sofisticadas, os algoritmos de predição de classes se tornam útil e realizam a fusão de imagens com melhor resolução espacial e temporal. Entre os algoritmos de classificação mais utilizados está o Random Forest, um algoritmo baseado em aprendizado de máquina, que realiza as predições e classificações através de um conjunto de árvores de decisão independentes.[146] O algoritmo RF é um método de aprendizagem por conjunto usado para classificação, regressão e outras tarefas. Serão testadas variações das propriedades, como número de árvores, número de árvores considerado em cada divisão, treinamento replicável e distribuição das classes de equilíbrio. Para controle de crescimento da floresta, serão testadas variações de limite de profundidade de árvores individuais e limite para não divisão de subconjuntos.[150]

2.5.3. O K-Vizinhos mais próximos (KNN)

O K-Vizinhos mais próximos (KNN) não visa construir modelo de generalização, funcionando, basicamente, por meio do armazenamento dos dados de treinamento. A classificação de uma instância é feita com base no seu posicionamento no plano que armazena os dados de treinamento e na análise dos seus k vizinhos mais próximos, de forma que, se eles pertencerem, em sua maioria, a uma classe x, a instância em questão será classificada como sendo da classe x.[149,151]

O K-Vizinho mais próximos é um algoritmo supervisionado que pode ser utilizado tanto para tarefas de classificação quanto para tarefas de regressão. No entanto, sua maior aplicação é em problemas de classificação. Esse algoritmo classifica um determinado registro de acordo com a classe majoritária de seus vizinhos mais próximos, obedecendo às seguintes regras de BRUCE em 2019: Encontrar K registros que possuam características similares ao registro que será classificado; Para a classificação, descubra qual é a classe majoritária entres os registros semelhantes e atribua essa classe para o registro; Para a regressão, encontre a média entre aqueles registros semelhantes e preveja essa média para o novo registro.[146]

O algoritmo “K-vizinhos mais próximos procura K exemplos de treinamento mais próximos no espaço de recursos e usa sua média como previsão. Serão testadas como métricas dos modelos as distâncias Euclidiana, Manhattan, Máxima e Mahalanobis, além de variações entre pesos uniformes e distância como critérios dos modelos. O pré-processamento padrão do algoritmo será mantido[150]

O algoritmo KNN utiliza a hipótese de que dados similares tendem a se concentrarem em uma mesma região do espaço, assim, os vizinhos mais próximos de uma instância são definidos a partir do cálculo da medida de proximidade.[152]

O algoritmo utiliza um conjunto de dados conhecido (dados de treinamento) e classifica o novo dado a partir do cálculo da distância entre eles, sendo que a nova classe será a mesma do dado que estiver mais próximo.

Em outras palavras, o algoritmo KNN calcula o K vizinhos mais próximos e, se os vizinhos mais próximos forem majoritariamente de uma classe, o novo dado será classificado de acordo com essa classe. A escolha da medida de proximidade utilizada no processo de classificação, é determinante para o sucesso do algoritmo.[152,153]

2.5.4. Rede Neural Convolucional (RNC)

Ferramenta de aprendizagem de máquina bastante adequada para analisar o problema de classificação de imagens de Satelite é a rede neural convolucional. Redes neurais, um subgrupo dentro do aprendizado de máquina, algoritmos desenhados de modo a emular o funcionamento do cérebro humano, composto por uma série de funções aninhadas, que formam uma rede de nós interligados em camadas, as quais podem ser ativadas ou desativadas de maneira análoga à sinapse entre dois neurônios. A rede neural de convolução é um tipo particular de rede neural que utiliza um conjunto dessas camadas para encontrar padrões em comum em partes de uma imagem, como uma janela que vai rastreando essa imagem para encontrar pontos de contraste, identificáveis em mais de um caso de imagens semelhantes, mas não necessariamente idênticas.

Uma Rede Neural Convolucional (RNC), área de estudo que busca desenvolver a capacidade de captação, processamento e interpretação de informação visual por uma máquina para identificar características comum, considerando o conjunto de dados analisados para realizar o processo de classificação de imagem de satélite da região Amazônica Brasileira. RNC é um tipo especializado de rede neural projetada para processar dados com estrutura em grade, como imagens.

As RNC foram amplamente utilizadas em tarefas de visão computacional e têm obtido resultados impressionantes em reconhecimento de padrões, classificação de imagens, detecção de objetos, segmentação semântica e outras tarefas relacionadas a imagens. A principal característica das RNC é a camada de convolução, que aplica filtros ou kernels a uma imagem de entrada para extrair recursos ou características relevantes. Esses filtros são pequenas matrizes que percorrem a imagem e são multiplicados pelos valores dos pixels em cada posição, produzindo um mapa de características ou feature map que destaca a presença de padrões específicos na imagem.

As RNC incluem camadas de pooling, que reduzem a dimensionalidade dos mapas de características, diminuindo o tamanho dos recursos extraídos. As camadas totalmente conectadas também são usadas para realizar classificação ou outras tarefas de aprendizado.

A capacidade das RNC de aprender características diretamente dos dados, sem a necessidade de extração manual de recursos, é uma das razões para seu sucesso. As RNC são treinadas usando algoritmos de aprendizado supervisionado. Para tarefas de classificação de imagens, a rede é alimentada com um conjunto de imagens rotuladas e é treinada para atribuir as classes corretas às imagens.

As redes neurais convolucionais são projetadas especificamente para processamento de imagens e têm sido fundamentais para os avanços na visão computacional e em muitas outras áreas relacionadas ao processamento de dados em grade.

Alguns parâmetros que influenciam diretamente no comportamento e performance de uma rede Convolucional: número de filtros (kernel), tamanho dos filtros, stride (deslocamento do filtro ao longo da imagem de entrada), pooling (redução da dimensão espacial dos mapas ao longo das camadas da rede), camadas densas, escolhas de função de ativação, dentre outros tantos conceitos.[154]

Redes de aprendizado profundo técnicas de aprendizado profundo[154] consiste em utilizar um grafo, composto por várias camadas de processamento, para modelar abstrações de alto nível nos dados. Redes neurais convolucionais têm como princípio explorar propriedades topológicas que imagens, vídeos ou sinais de áudios possuem, ou seja, a relação que valores vizinhos compartilham.[155]

O caminho de contração é característico de uma Rede Neural Convolucional, com duas etapas principais: (a) o processo de convolução e (b) de sub-amostragem. A camada de convolução é composta por um filtro de tamanho menor do que a imagem original, que é completamente escaneada. Esses múltiplos núcleos de convolução conseguem extrair as informações características das imagens, aprendendo não apenas as informações espectrais, mas também da textura de dimensão espacial. Dessa forma, a arquitetura de uma Rede Neural Convolucional, e o processo de convolução, é dado através da aplicação de filtros[156].

O filtro kernel é formado por valores aleatórios de inicialização, que são ajustados de forma interativa durante o processo de treinamento. Para cada parte da estrutura de uma RNC, uma quantidade n de kernels de tamanho m x m podem ser aplicados, resultando em uma quantidade n de matrizes. Posteriormente, em uma camada de pooling, os resultados da camada de convolução são sub-amostrados em blocos menores, através da aplicação de filtros com dimensões menores do que as imagens resultantes do processo anterior. Esse processo consiste em calcular uma média, ou o valor máximo dos pixels contidos no filtro. Quanto mais profunda as camadas vão ficando, a importância relativa dos filtros diminui, e a dos conjuntos de filtros aumentam, o que torna possível a identificação das características a nível de objeto.[156,157]

O caminho de contração de uma arquitetura U-Net consiste então na aplicação repetida de duas camadas de convolução, seguidas da aplicação da função de ativação ReLu (Unidade Linear Retificada) e uma operação de maximum pool. Para cada etapa de amostragem, o número de mapas de recursos é dobrado. No caminho de expansão, o método de convolução transposta é aplicado, onde cada blocos de imagem são submetidos a duas camadas de convolução, seguido por uma camada de amostragem. O número de blocos de expansão é igual ao número de blocos de contração. Na camada final é aplicada uma camada de convolução 1x1 para gerar o resultado de saída final. A U-Net também precisa passar por um processo de treinamento, onde seus parâmetros são ajustados através de imagens de

satélite amostradas, que contêm as máscaras associadas as cicatrizes de deslizamento. Essas máscaras são representativas da classe de interesse, as quais a rede neural deve utilizar para aprender a diferenciar os objetos tidos como de interesse dos demais.[157]

As RNCs em conjunto com as Imagens Hiper espectrais têm sido utilizadas em um grande número de pesquisas na área de classificação do uso e cobertura da terra, utilizando diferentes abordagens com emprego de variáveis espaciais e espectrais.[158]

Sobre a segmentação de instâncias, a idealização do conceito de separação dos objetos além dos seus tipos e semelhantes se mostra um desafio real e que está sendo frequentemente abordado e melhorado.[168]

As dificuldades enfrentadas na segmentação de instâncias e na detecção de objetos em si, pode criar um produto capaz de utilizar a abordagem dos demais métodos conhecidos, apresentando um modelo simplificado para segmentação de instância utilizando uma rede neural Convolucional completa, e dividindo a segmentação em dois processos paralelos, gerando a máscara de protótipos e prevendo os coeficientes das máscaras, conseguindo um desempenho muito superior na criação das máscaras de instância definitivas, combinando os resultados.[161]

As informações úteis para a análise dos pixels em cada nível da rede neural podam se propagar diretamente para as seguintes sub-redes, criando uma ramificação complementar que captura diferentes visões para a proposta, criados para melhorar a definição da máscara final.[162]

A utilização de Redes Neurais Convolucionais ainda possui alguns desafios relevantes. Algumas características da RNC frente a outras técnicas de predição e classificação de imagens que podem ser observadas como desvantagens.[73] Requer uma quantidade consideravelmente alta de dados; Demanda alto poder computacional (dependendo da aplicação); O ajuste de parâmetros de uma RNC pode ser extremamente difícil para determinada aplicação.[74]

2.5.5. Classificação de imagem de satélite da Região Amazônica Brasileira

É extremamente necessário a realização de tratamento de imagens de satélite da Região Amazônica Brasileira, sobretudo, as que possuem nuvens e sombras, a partir, da utilização de dados de qualidade, redução de impactos e fatores indesejados, como ruídos, distorções geométricas, variações atmosféricas.

A classificação de imagens pode ser realizada de inúmeras formas, que variam entre a manual, como a fotointerpretação, até as automáticas, que adotam algoritmos de classificação. As mais apropriadas para classificação de uso e cobertura da terra são as semiautomáticas. As referidas classificações, no entanto, estão sujeitas a distintos níveis de subjetividade.[225]A Análise de Imagens Baseada em Objetos Geográficos pode ser considerada um método semiautomático de classificação de imagens de Sensoriamento Remoto (BLASCHKE, 2010; HAY; CASTILLA, 2008). A GEOBIA é composta por dois procedimentos sequenciais: segmentação e classificação. A segmentação é o processo de dividir a imagem em agrupamentos de pixels homogêneos. A qualidade e acurácia dos resultados dependem significativamente deste procedimento. Os objetos gerados na segmentação são classificados a partir de seus atributos. Suas características espaciais ou hierárquicas são expressas pela quantificação das informações multiespectrais, geométricas, texturais ou relacionais. Os dois procedimentos de atribuição de classes aos objetos são: baseada em regras e vizinho mais próximo. [225]

As imagens de satélite são capturadas por sensores embarcados em satélites. Esses sensores são projetados para registrar a radiação eletromagnética refletida ou emitida pela superfície terrestre em várias faixas espectrais, como o espectro visível, infravermelho próximo, infravermelho térmico, entre outros. As imagens de satélite fornecem uma representação visual da superfície terrestre e são usadas em uma variedade de aplicações, incluindo monitoramento ambiental. As imagens de satélite são normalmente disponibilizadas como arquivos digitais em formatos específicos, como Geo TIFF, JPEG, PNG ou ENVI, que podem ser visualizados e processados usando software especializado de análise de imagens de satélite. Essas imagens podem ser adquiridas por diferentes tipos de satélites, incluindo satélites ópticos, que capturam imagens usando sensores de luz visível e infravermelho próximo, e satélites de radar, que utilizam ondas de rádio para obter informações sobre a superfície terrestre, independentemente das condições climáticas ou de iluminação.

A classificação de imagens de satélite apresenta muitos avanços científicos, aprimoramento de técnicas, métodos, ferramentas, procedimentos. Mas, a região Amazônica Brasileira é conhecida por sua cobertura densa de florestas e a presença de nuvens. A realização de classificação de imagens de satélite na região Amazônica Brasileira ainda

apresenta desafios específicos, devido às características peculiares da cobertura terrestre e à complexidade da vegetação tropical.

O crescimento computacional, a evolução das características dos sensores e a disponibilidade de dados de satélite impulsionaram o desenvolvimento de novos métodos de classificação de imagens.[172] Cada classificador tem seu processo de operação específico e, ou seja, os resultados podem variar, dependendo do classificador.[173] Os métodos mais utilizados atualmente para classificação de imagens são os supervisionados através de classificadores de aprendizado de máquina, especialmente os baseados em análise pixel a pixel.[172] Estes algoritmos usam amostras de locais de treinamento para classificação, através de assinaturas espectrais únicas atribuídas a cada classe pelo usuário.[173] A escolha do algoritmo ideal depende de parâmetros como condições do local, dados existentes e similaridade espectral das classes.[173]

O uso do Random Forest (RF) para a classificação de imagens do S-2 tem obtido resultados com alta acurácia.[172,173,110]O sensoriamento remoto junto ao campo da inteligência artificial tem recebido grande destaque na linha de modelagem ambiental. Aproveitar o uso de imagens de alta resolução espacial e temporal se faz necessário para manter a observação frente aos desafios de um país detentor de uma grande porção de vegetação.

Para classificar imagens, treinar e rotular o pixel, utiliza-se classificação supervisionada e não-supervisionada.[163] Na classificação supervisionada define-se as amostras de treinamento previamente. O algoritmo classifica todos os pixels, ou objetos, de acordo com alguma regra de decisão. A classificação não-supervisionada o computador separa o pixel, ou objeto/região, dentro de uma classe, utilizando algoritmos computacionais, permitindo uma maior uniformidade da composição espectral, não necessitando de conhecimento prévio das classes.[164]

A implementação de um robusto sistema de classificação é crucial para o sucesso de mapeamento e acurácia temática, e que a acurácia de um mapa depende de muitos fatores, incluindo nível de detalhes (esquemas de classificação) e a variabilidade das categorias a ser mapeada. [164, 165]

Na aprendizagem não supervisionada, o agente aprende padrões na entrada, embora não seja fornecido nenhum feedback explícito; em aprendizagem por reforço, o agente aprende a partir de uma série de reforços – recompensas ou punições; na aprendizagem supervisionada, o agente observa alguns exemplos de pares de entrada e saída, e aprende uma função que faz o mapeamento de entrada na saída.[132]

A classificação de imagem de satélite da Região Amazônica Brasileira pode ser realizada a partir da análise de uma grande quantidade de dados. Os dados são carregados

em um banco de dados geográfico e analisados com algoritmos selecionados de acordo com o problema a ser resolvido.

A classificação de imagens de satélite é uma tarefa comum em visão computacional e processamento de imagens, onde o objetivo é atribuir rótulos ou categorias a cada pixel ou região de uma imagem obtida por satélite. Essa classificação permite identificar e mapear características ou objetos específicos presentes na cena capturada pela imagem.

As imagens de satélite possuem informações espectrais em várias bandas do espectro eletromagnético, como infravermelho próximo, infravermelho médio e infravermelho térmico, além do espectro visível. Essas informações espectrais podem ser utilizadas para distinguir diferentes tipos de cobertura terrestre, como florestas, entre outros.

Existem várias abordagens para a classificação de imagens de satélite, incluindo métodos tradicionais baseados em técnicas de processamento de imagem e extração de características, bem como abordagens baseadas em aprendizado de máquina, como as redes neurais convolucionais. As RNC têm sido amplamente utilizadas na classificação de imagens de satélite devido à sua capacidade de aprender recursos diretamente dos dados.

Utilizar técnicas de combinação em problemas de Aprendizado de Máquina pode ser especialmente eficaz por três motivos principais.[166] Estatístico: quando a quantidade de dados para treinamento é muito pequena, os algoritmos podem encontrar diversas hipóteses para resolução do problema. Realizar a média dessas hipóteses reduz o risco de escolher o classificador errado. Computacional: um classificador construído através de diferentes pontos de partida pode fornecer melhor aproximação da função a ser encontrada do que classificadores individuais. Representacional: quando a função desejada não pode ser representada, é possível expandir o espaço de representações utilizando somas ponderadas das hipóteses obtidas pelos classificadores.[167]

2.5.6. Trabalhos Similares

Redes neurais convolucionais é creditada a Fukushima,[82] ResNet50 foi criada a partir de um estudo que mostra que apenas o aumento das camadas de convolução nas redes de aprendizado profundo, não garante a melhoria de performance. Os autores perceberam que o aumento do número de camadas melhorava o desempenho da rede até certo ponto, a partir de um dado número de camadas adicionais a performance da rede piorava.[167] As redes convolucionais foram treinadas utilizando as imagens da Amazônia Brasileira e testadas em imagens nos trópicos úmidos da Austrália. A avaliação dos resultados nas imagens da Austrália foi feita apenas de forma visual, pois não foi obtido nenhum conjunto de dados para realizar a análise quantitativa.[184,185] Apresentou uma análise comparativa para a classificação de imagens de satélite utilizando abordagens de aprendizado profundo. O modelo utilizado

por Chen propôs uma RNC baseada em redes profundas para a classificação de imagens de satélite. Esta rede foi projetada para lidar com problemas complexos de alta dimensionalidade e foi treinado utilizando um extenso dataset.[224]

O trabalho avaliou o desempenho dos classificadores Support Vector Machine (SVM) e KNN em imagens CBERS-4 e Sentinel-2 no mapeamento de uso de ocupação da terra no município de Piracicaba-SP. A partir da segmentação das imagens e aplicação de técnicas de classificação orientada a objetos, foram definidas as classes de uso e ocupação da terra e colhidas amostras de treinamento. O processo de classificação foi feito para as imagens CBERS-04A e Sentinel-2 utilizando em ambas as mesmas amostras de treinamento e aplicando em cada uma delas tanto o algoritmo KNN, quanto o SVM, gerando 4 diferentes mapas de uso e ocupação da terra. A avaliação dos resultados se deu pelos métodos Índice Kappa e Exatidão Global e foi possível verificar a similaridade entre os resultados da aplicação do algoritmo SVM nas duas imagens, assim como a similaridade entre os resultados da aplicação do KNN nas duas imagens.[229]

O trabalho apresentou resultados da classificação de regiões em imagens do satélite Sentinel-2 da Área de Preservação Ambiental de Itupiranga, especificamente no entorno da represa de Itupiranga, no Estado de São Paulo. Através do pré-processamento e utilização de índices espectrais (NDVI, GNDVI, NDWI, MNDWI e NDBI) foi feita a classificação da cobertura do solo da região usando as técnicas de inteligência artificial: Random Forest (RF) e SVM.[96]

3. Metodologia

A Metodologia apresenta as etapas executadas para alcançar os objetivos deste estudo. O Estudo utilizou Inteligência Artificial, Aprendizado de máquina, Algoritmos: KNN, RF e RNC. Técnicas de Geoprocessamento e Sensoriamento Remoto para realizar o processamento de imagens de satélite, analisando o desmatamento na região Amazônica Brasileira. Os algoritmos foram elaborados através da ferramenta de classificação Dzetsaka, plugin disponível a partir da versão do QGIS 2.0. Considerou a viabilidade de uma análise comparativa para a classificação de imagens de satélite, utilizando três modelos: Modelo Geo-RNC, Modelo Geo-KNN, Modelo Geo-RF.

A estratégia foi realizar experimentos em um grande banco de dados, que foi utilizado para treinar a máquina, de modo a extrapolar o treinamento e ser capaz de realizar as tarefas diante de uma nova informação. Assim, na presença de uma nova informação, uma nova imagem, o algoritmo foi capaz de classificar a presença do desmatamento ou não com base na presença ou não dessas características aprendidas. Considerando rótulos mais específicos das classes: CORTE RASO, QUEIMADAS, MINERAÇÃO e ÁREAS DE PROTEÇÃO AMBIENTAL.

Então o algoritmo, com base nesse banco de dados, identificou as características em comum entre as imagens de cada conjunto. A cada nova informação, nova imagem, o algoritmo foi capaz de classificar a presença do desmatamento ou não com base na presença ou não dessas características aprendidas com base no banco de dados.

A adoção de métodos alternativos de aprendizado de máquina utilizado potencializou os resultados de acurácia. Em suma, a metodologia adotada neste estudo objetivou analisar algoritmos com a melhor aprendizagem e acurácia de previsão.[141] *Por isso, este trabalho utilizou os três algoritmos: KNN, RF e RNC*. O uso dos algoritmos utilizados justifica-se por diversos fatos:

Observou-se que a maior dificuldade durante a classificação das imagens utilizando Geoprocessamento e Sensoriamento Remoto foi diferenciar pixels de AREA VERDE com AREAS DE PROTEÇÃO AMBIENTAL, identificar precisamente pixels de AREAS DE CORTE RASO, AREAS DE MINERAÇÃO, QUEIMADAS, buscando contornar a situação, foi realizada a combinação dos três algoritmos KNN, RF e RNC.

O uso de RF mostra alta precisão devido ao produto com alta resolução espacial e espectral no estudo.[111,115] Outros algoritmos foram testados, os algoritmos apresentaram dificuldades de classificar algumas amostras. O classificador não obteve bons resultados gerais se comparados aos algoritmos utilizados. Uma característica distintiva do Random

Forest é sua habilidade em avaliar a importância das características durante o processo de classificação. Essa capacidade ofereceu insights valiosos sobre quais aspectos dos dados são mais informativos para o modelo, proporcionando uma maior compreensão e interpretabilidade. O Random Forest é aplicável em uma ampla gama de domínios, desde a classificação de imagens, detecção de fraudes, até análise de texto e bioinformática. Sua versatilidade ao lidar com diferentes tipos de dados e sua eficácia em grandes conjuntos de dados o tornam uma escolha popular entre cientistas de dados e engenheiros de aprendizado de máquina.[160] O algoritmo Random Forest tem atraído crescente interesse devido à sua precisão e robustez em comparação com classificadores individuais. Opera eficientemente em grandes conjuntos de dados, sendo capaz de processar milhares de variáveis de entrada sem a necessidade de exclusão. Adicionalmente, apresenta uma carga computacional mais leve em comparação com outros métodos baseados em conjuntos de árvores. O uso do Random Forest (RF) para a classificação de imagens tem obtido resultados com alta acurácia.[172,173,110]

O algoritmo KNN foi utilizado na forma de classificação supervisionada dos dados, com a função euclidiana de distância. É um algoritmo de ML usado para resolver problemas de classificação e regressão,[188]baseado nos k vizinhos mais próximos, onde k é um valor inteiro especificado[189]. No Dzetsaka,[189] este parâmetro (número de vizinhos) foi escolhido em um método de validação cruzada para maximizar a qualidade dos resultados.[190]

As RNCs em conjunto com as Imagens Hiper espectrais têm sido utilizadas em um grande número de pesquisas na área de classificação do uso e cobertura da terra, utilizando diferentes abordagens com emprego de variáveis espaciais e espectrais.[158]As RNC foram um marco significativo no campo do aprendizado de máquina e processamento de imagens. Desde sua introdução, as RNC têm demonstrado um desempenho excepcional em tarefas de visão computacional, incluindo reconhecimento de objetos, detecção de características e classificação de imagens. As RNC são capazes de aprender de forma independente as características importantes em diferentes níveis de abstração. Essa habilidade é alcançada por meio do uso de camadas convolucionais, que aplicam filtros para extrair características locais das imagens e, em seguida, combinam essas informações em camadas subsequentes.[225]

3.1. O Modelo de Geo-RNC

A Figura 4 apresenta o Modelo que utiliza Geoprocessamento, SR, e Rede Neural Covolucional (Geo-RNC). O modelo considera abordagens de Inteligência Artificial, Aprendizado de máquina, Rede Neural Covolucional (RNC) para classificar imagens de satélite analisando o desmatamento na região Amazônica Brasileira, considerando as classes: Corte raso, Queimada, Mineração, Área de Proteção Ambiental.

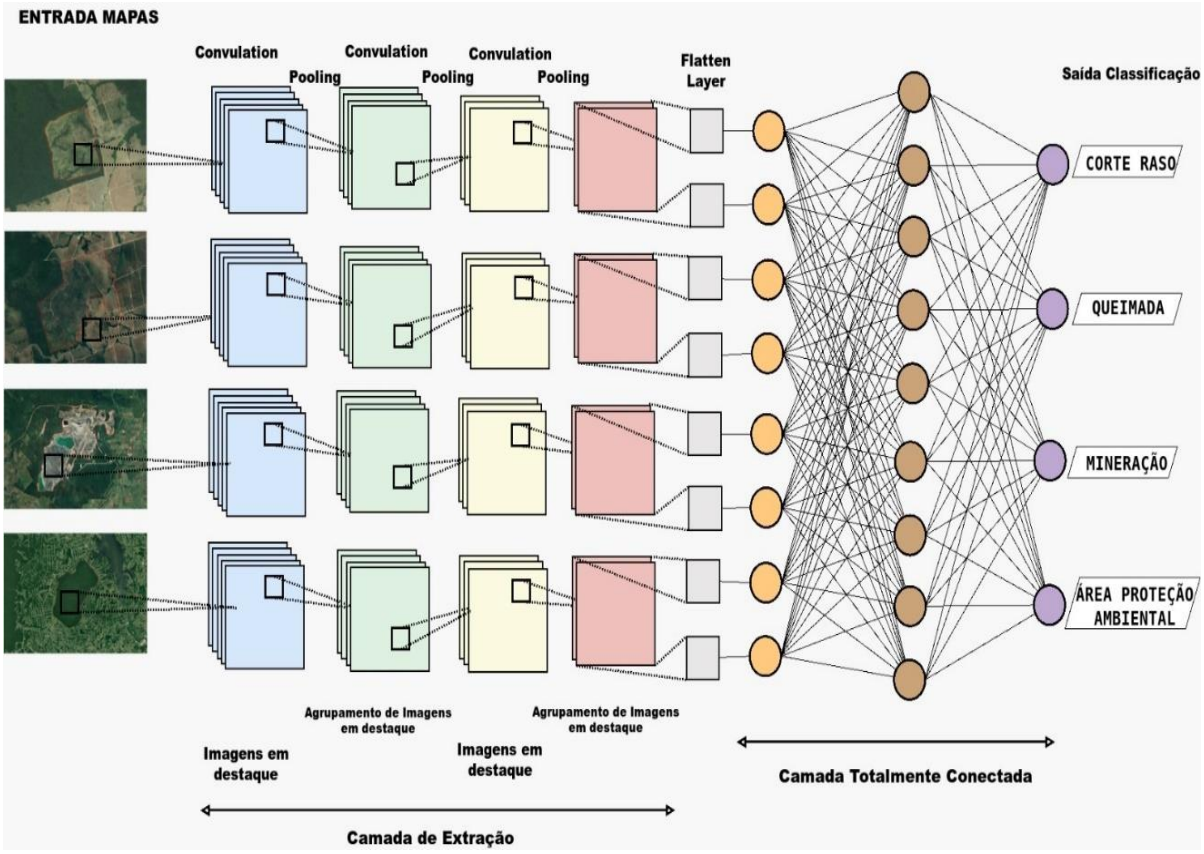

Figura 4 - O modelo RNC
Fonte: Autor

A RNC, composta pelos elementos conhecidos de uma rede neural profunda (camada de entrada, camada escondida, função de ativação), mais um elemento novo: a camada de convolução (convolutional layer). Cada pixel da imagem do satelite como um sinal de entrada do input layer, cada neurônio da camada de convolução ligada somente aos neurônios de entrada correspondentes ao seu campo receptivo.[193] Uma segunda camada convolucional ligada a um retângulo de neurônios da primeira camada.

A RNC possui uma camada de junção (pooling layer) que, assim como a camada de convolução, ligada a apenas alguns neurônios da camada anterior, agregando os sinais de

entrada (com uma função de máximo ou de média, por exemplo), de modo a reduzir o tamanho da imagem de entrada, o que melhora o desempenho computacional do processamento da rede[193]

A hipótese levantada foi que era difícil para o modelo GeoRNC o treinamento e analise comparativa para a classificação de imagens de satélite usando recortes previamente classificados e rotulados, ou seja, a distinção entre o que era parcialmente CORTE RASO e parcialmente QUEIMADAS; a distinção entre o que era parcialmente CORTE RASO e parcialmente MINERAÇÃO; a distinção entre o que era parcialmente AREA VERDE e parcialmente AREAS DE PROTEÇÃO AMBIENTAL. Por isso, foi realizada a troca e analise pontual de alguns rótulos. Assim como, foi necessário estender o Dataset das imagens. Pois, o modelo considerou uma análise comparativa para a classificação de imagens de satélite.

As camadas convolucionais possibilitaram a extração de informações relevantes em diferentes escalas, enquanto as camadas de pooling reduziram a dimensionalidade e a demanda computacional. A adição de mais camadas de convulação na RNC refletiu em melhores resultados. Mas, Adicionar mais camadas densas foi muito custoso computacionalmente. Para não ter que definir cada uma das camadas individualmente, foram criados blocos de convolução que se repetiriam ao longo da rede. As redes utilizadas iniciam com quatro blocos de convoluções ligados uns aos outros pela operação de max pooling, seguidos por uma camada densa e finalizando com uma função soft-max. [178]

3.2. Modelo Geo-KNN

O Modelo utiliza GEO, SR e K-vizinhos mais próximos (Geo-KNN). O modelo usado encontra-se alinhado aos os objetivos deste trabalho, considerando diversos estudos. O modelo integra GEO, SR e Inteligência Artificial, considerou uma análise comparativa para a classificação de imagens de satélite. O Modelo Geo-KNN utilizou técnicas de Geoprocessamento e Sensoriamento Remoto para realizar o processamento de imagens de satélite, analisando o desmatamento na região Amazônica Brasileira. Considerou abordagens de Inteligência Artificial, Aprendizado de máquina, aprendizado profundo, algoritmo K-vizinhos mais próximos (KNN) para classificar imagens de satélite analisando causas de desmatamento na região Amazônica Brasileira, considerando as classes: Corte raso, Queimada, Mineração, Área de Proteção Ambiental.

O algoritmo classificou novos pontos ou amostras com base na aproximação numérica a outros pontos/amostras classificadas, na fase de treinamento. Na prática, cada pixel da imagem de satélite foi classificado com base em um conjunto de pixels similares previamente rotulados na etapa de pré-processamento.

No Dzetsaka[189] criou-se uma camada vetorial com um campo de classificação que foi mapeado para a banda de satélite. Cada classificação corresponde a um recorte da área de interesse a qual a classificação corresponde. Na pratica, foi elaborado um modelo para classificar uma grande área com base em pequenas amostras da própria imagem.

Durante a fase de testes, não foi possível aplicar o modelo em algumas regiões geoespacial, devido as peculiaridades da obtenção de cada imagem, considerando as tecnologias disponível de cada satélite.

O modelo Geo-KNN realizou as seguintes fases: Aquisição de imagens: foi usado Imagens de satélite com alta resolução espacial, fornecidas pelo CBERS-4. Permitiu capturar detalhes finos da vegetação e dos objetos terrestres, auxiliando a capacidade dos algoritmos para distinguir diferentes classes. Aumentar o tamanho e a qualidade do conjunto de treinamento: foi selecionado um conjunto de treinamento diversificado e representativo da região Amazônica Brasileira: Imagens que abrangem diferentes tipos de cobertura terrestre, florestas primárias, áreas desmatadas, áreas urbanas, áreas de mineração, áreas de proteção ambiental, (imagens representativas de todas as classes de interesse); amostras adequadas de cada classe de interesse para garantir que a rede neural possa aprender características distintivas de cada uma. A cada pixel ou região foi utilizado rótulos de qualidade. Dados de treinamento: O algoritmo KNN começou com um conjunto de dados de treinamento que incluiu exemplos com rótulos conhecidos. Cada exemplo consistiu em recursos (atributos) e classe (s) associada (s). Seleção de um valor de K: Foi selecionado o número de vizinhos mais próximos que foram considerados para realizar as previsões. O valor de K correspondeu a um hiper parâmetro que foi ajustado, de acordo com a natureza dos dados treinados. Medição de distância: Para executar o Algoritmo KNN foi utilizado uma medida de distância. A distância euclidiana foi utilizada para calcular a distância entre o ponto de dados de teste (Cálculo utilizado para realizar as previsões) e todos os pontos de dados no conjunto de treinamento. Encontrar os K vizinhos mais próximos: O algoritmo identificou os K pontos de dados do conjunto de treinamento mais próximos ao ponto de dados de teste, com base na medida de distância escolhida. Votação: Para problemas de classificação, o KNN realizou uma votação entre os K vizinhos para determinar a classe mais comum entre eles. A classe mais comum foi escolhida como a previsão para o ponto de dados de teste. Previsão: Com base na votação (para classificação), o KNN fez a previsão para o ponto de dados de teste. Avaliação: O desempenho do modelo foi avaliado usando métricas apropriadas, como precisão (para classificação).

A hipótese levantada foi que era difícil para o modelo GeoKNN o treinamento e analise comparativa para a classificação de imagens de satélite usando recortes previamente classificados e rotulados, ou seja, a distinção entre o que era parcialmente CORTE RASO e parcialmente QUEIMADAS; a distinção entre o que era parcialmente CORTE RASO e parcialmente MINERAÇÃO; a distinção entre o que era parcialmente AREA VERDE e parcialmente AREAS DE PROTEÇÃO AMBIENTAL. Por isso, foi realizada a troca e analise pontual de alguns rótulos. Assim como, foi necessário estender o Dataset das imagens. Pois, o modelo considerou uma análise comparativa para a classificação de imagens de satélite.

3.3. Modelo Geo-RF

O Modelo utilizou Geoprocessamento e "Floresta Aleatória" (Geo-RF). O modelo elaborado encontra-se alinhado aos os objetivos deste trabalho. O modelo integra Geoprocessamento, Inteligência Artificial, considerou uma análise comparativa para a classificação de imagens de satélite. o Modelo Geo-RF utilizou técnicas de Geoprocessamento e Sensoriamento Remoto para realizar o processamento de imagens de satélite, analisando o desmatamento na região Amazônica Brasileira. Considera abordagens de Inteligência Artificial, Aprendizado de máquina, aprendizado profundo, algoritmo "Floresta Aleatória" (RF) para classificar imagens de satélite analisando causas de desmatamento na região Amazônica Brasileira: Corte raso, Queimada, Mineração, Área de Proteção Ambiental.

O algoritmo RF executou uma combinação de árvores de decisão para modelar um relacionamento não linear de alto grau entre as variáveis alvo e previstas.[191,192]O algoritmo usou agregação bootstrap para criar múltiplas formações de subconjuntos para obter variedade de árvores.[191] O classificador de floresta aleatório combinou vários classificadores de árvore de decisões aplicadas a uma amostra do vetor de dados de entrada. Cada árvore de decisão vota na classe mais provável.[191]

O classificador de floresta aleatório usou o índice Gini para selecionar atributos que predizem as classes. O algoritmo escolheu a classe de cada pixel que recebeu mais votos. O algoritmo pode ser descrito nas fases: Coleta de dados: O primeiro passo consistiu em coletar um conjunto de dados de treinamento que contém exemplos rotulados. Cada exemplo consiste em várias características (ou atributos) e um rótulo que indica a classe (no caso de classificação). Criação de árvores de decisão: O RF criou várias árvores de decisão individuais. Cada árvore é construída a partir de uma amostra aleatória do conjunto de dados de treinamento. A cada passo da construção da árvore, o algoritmo considerou apenas um subconjunto aleatório das características. Essa aleatoriedade ajudou a reduzir o super ajustamento (overfitting) e tornou as árvores mais independentes. Tomada de decisão: Quando foi necessário realizar uma previsão para uma nova amostra, o RF passou uma

amostra por todas as árvores de decisão, com o objetivo de obter as previsões individuais de cada árvore. Para classificação, as previsões foram frequentemente combinadas por voto majoritário (ou seja, a classe mais comum é escolhida). Avaliação da precisão: A precisão do modelo RF foi avaliada usando métricas apropriadas, como acurácia, F-Score.

O algoritmo RF, no Dzetsaka,[189] trabalhou com a geração de N árvores de decisão, onde N é o número de classes ou classificações. Para cada classe tem-se três árvores bases, uma para cada valor do pixel formada pelas três bandas que compõe uma imagem de satélite (composição RGB – Red, Green, Blue, ou RGI – Red, Green, Infravermelho), dependendo do processamento do satélite. De modo didático, temos x1 valor do pixel na banda 1, x2 na banda 2 e x3 na banda 3.[190]

A hipótese levantada foi que era difícil para o modelo GeoRF o treinamento e analise comparativa para a classificação de imagens de satélite usando recortes previamente classificados e rotulados, ou seja, a distinção entre o que era parcialmente CORTE RASO e parcialmente QUEIMADAS; a distinção entre o que era parcialmente CORTE RASO e parcialmente MINERAÇÃO; a distinção entre o que era parcialmente AREA VERDE e parcialmente AREAS DE PROTEÇÃO AMBIENTAL. Por isso, foi realizada a troca e analise pontual de alguns rótulos. Assim como, foi necessário estender o Dataset das imagens. Pois, o modelo considerou uma análise comparativa para a classificação de imagens de satélite.

3.4. Materiais e Métodos

O levantamento bibliográfico foi realizado a partir do inter-relacionamento de bases de dados, de desmatamento (por corte raso), desmatamento (por queimadas), áreas de mineração, e Áreas de proteção Ambiental, entre 2001 a 2022.

O levantamento bibliográfico foi realizado considerando os objetivos deste estudo: Monitorou dados de desflorestamento dos municípios de Altamira e São Felix do Xingu, estado do Pará, Região Amazônica, Brasil, utilizando Inteligência Artificial, GEO e SR, no período de 2001 a 2022. Utilizou aprendizado de máquina, os algoritmos KNN, RF, e a RNC para classificar imagens de satélites; realizou o aprendizado de parâmetros de identificação das classes de áreas de Florestas (considerando corte raso e queimadas), Áreas de mineração, áreas de proteção Ambiental. Combinou Inteligência Artificial, GEO e SR para analisar as relações entre os dados de desflorestamento de corte raso e queimadas; relacionando-os com áreas de proteção ambiental, surgimento de rodovias, atividades de mineração, decorrentes de ações antrópicas. Classificou imagens de satélites utilizando Inteligência Artificial, GEO e SR, para identificar e analisar os resultados qualitativos de desflorestamento, a partir da interpretação visual das imagens processadas; classificou imagens de satélites utilizando Inteligência Artificial, GEO e SR, para identificar e analisar os resultados quantitativos de desflorestamento, a partir das métricas utilizadas.

Base Digital Georreferenciada (BDG): contém dados de limite municipal, sistema viário, uso e cobertura da terra,[92,93] construídos a partir de imagens do satélite CBERS 4. Base de Desmatamento na Amazônia Brasileira: Corresponde aos dados quantitativos de área desmatada em Km^2 geradas através do projeto PRODES. O projeto realiza o monitoramento por satélite do desmatamento por corte raso na Amazônia Brasileira, desde 2001. Esses dados foram submetidos ao processo de associação vetorial para análises quantitativas por município e estados, no software QGIS 3.10.[187]Base do uso e cobertura da terra: Contém imagens de satélites de áreas referente ao estudo de municípios para análise sobre cobertura da vegetação após os 5 anos de desmatamento (municípios de Altamira e São Felix do Xingu).

Base de Focos de Queimadas, a base de queimadas foi adquirida do programa Queimadas.[161] O projeto de monitoramento operacional de focos de fogo ativo de queimadas realiza: o monitoramento de incêndios florestais detectados por satélites; o cálculo e a previsão do risco de fogo da vegetação; o mapeamento das cicatrizes de áreas queimadas.

Base de Áreas Florestal, de Preservação e Proteção, essa etapa foi realizada em ambiente Quantum GIS (QGIS) 3.10. Neste ambiente foram filtrados os arquivos vetoriais do uso e cobertura da terra. A área de maior impacto ambiental foi identificada. Esta identificação

contribuiu com análises via interpretação visual, de acordo com os padrões identificados nas imagens (cor, tonalidade e forma). Como suporte à identificação dos padrões, foram utilizadas as imagens dos anos de 2001 a 2022. O histórico de uso e cobertura da terra foi verificado.

Integração dos Dados, os dados identificados foram integrados. Bases geográficas de desmatamento foram correlacionadas com bases geográficas de focos de queimadas, áreas de florestas, áreas de preservação e proteção ambiental, surgimento de rodovias. Expressões visuais foram construídas a partir do inter-relacionamento das bases de dados geográficas correlacionadas, em forma de mapas digitais. Técnicas de álgebra de mapas foram utilizadas. O processamento, análise e mapeamento dos dados brutos, vetoriais e imagens rasters foram realizados no software livre QGIS 3.10.

Aquisição de imagens e pré-processamento. Os produtos foram identificados por meio de faixa de dados (folhas com metadados para análises). Obtenção das amostras e Tipo de Amostras. Manualmente/visualmente foram selecionadas as imagens de satélite.[94,95] As áreas escolhidas foram organizadas por meio de arquivos vetoriais em shapefile. O processo de análise das amostras foi realizado por meio do software QGIS 3.10. A coleta dos dados. Composição de falsa cor, por meio da ferramenta Google Earth, e Todos os arquivos foram armazenados em um banco de dados.

Identificação de Características da área de estudo. As características observadas na área de estudo foram definidas em sete classes e os atributos de cada item, bem como o identificador usado em todo o procedimento. Para identificar regiões em imagens de satélite da Amazônia Brasileira foi utilizado técnicas de segmentação e detecção de objetos. Aplicação de técnicas de segmentação para dividir a imagem em regiões semelhantes com base em características, como cor, textura e forma.

A avaliação do desempenho dos algoritmos de aprendizado de máquina foi realizada através de software QGIS 3.10. Os métodos RF, KNN, RNC. treinamento dos Modelos, ajustes e Métrica de Validação. As bandas espectrais e os índices espectrais (B02, B03, B04, B05, B06, B07, B08, B8A, B11, B12, NDVI, GNDVI, NDWI 1, NDWI 2, MNDWI, NDBI) foram utilizados como descritores. As amostras foram divididas em 70% para treino e 30% para validação.[111]

A métrica matriz de confusão foi utilizada para validação da classificação das imagens. Para a RF ocorreu uma seleção do número de árvores e o número de entradas para os valores avaliados.[194]

Pós-processamento: removeu falsos positivos ou falsos negativos das regiões identificadas. Processo realizado aplicando tamanho mínimo ou sobreposição com regiões conhecidas.

Coleta de dados: as imagens de satélite foram coletadas do satélite CBER-4. Imagens com várias bandas espectrais, cada uma representando uma faixa específica do espectro eletromagnético.

O Pré-processamento objetivou a correção de distorções geométricas, calibração radiométrica, correção atmosférica, fusão de bandas, normalização, entre outros processamentos, a fim de obter dados coerentes e utilizáveis para a classificação.

A Anotação e rótulos realizou o treinamento supervisionado, foi necessário ter um conjunto de imagens de satélite rotuladas, cada pixel ou região é atribuído a uma classe específica (por exemplo, vegetação, rodovia, mineração). Essa anotação foi realizada manualmente e com o auxílio de algoritmos de segmentação e rotulagem automática.

Os algoritmos foram treinados usando o conjunto de imagens de satélite rotuladas. O conjunto de treinamento foi alimentado à rede, e os pesos dos neurônios foram ajustados iterativamente usando algoritmos de aprendizado, como o gradiente descendente, para minimizar a função de perda e melhorar a capacidade da rede de realizar a classificação correta. (RNC). Após o treinamento, o desempenho foi avaliado usando um conjunto de validação ou teste. Isso permitiu verificar a precisão da classificação em dados não utilizados durante o treinamento e ajustar os parâmetros da rede.

Com a RNC treinada e validada foi possível usá-la para classificar novas imagens de satélite. A rede recebeu uma imagem de entrada e atribuiu rótulos ou categorias a cada pixel ou região, permitindo mapear diferentes características da paisagem ou monitorar mudanças ao longo do tempo. [195,196,197,70]

3.5. Classificação de imagens de satélite

Este trabalho utilizou o satélite CBERS-4, as imagens foram adquiridas da Divisão de Geração de Imagens (DGI), supervisionado pela Coordenação Geral de Observação da Terra (OBT) do INPE. Doze (12) bandas espectrais do satélite CBERS-4, sensor WFI, com resolução espacial de até 64 metros e largura da faixa imageada, de aproximadamente 866 Km foram selecionadas. A composição vermelho, verde e azul (Red, Green, e Blue, em inglês- RGB) e a fusão pancromática das bandas foram realizadas no software QGIS 3.10.

Este trabalho utilizou o satélite CBERS-4, para a aquisição de imagens de alta resolução, a Câmera de Campo Largo (WFI) tem a propriedade de fazer rápidas revisitas a certa área, em geral em menos de cinco dias. Com isso, atividades de monitoramento e vigilância podem ser mais apropriadamente executadas. Possui um verdadeiro caráter multiespectral e sua resolução passou para 64 metros no nadir, sem perder a capacidade de rápida revisita, pois manteve um grande campo de visada. Com resolução espacial de 20m; Resolução Temporal igual a 5 dias; Banda Espectral B, com resolução espectral 0,45 - 0,52µm. Banda Espectral G, resolução espectral 0,52 - 0,59µm, Banda Espectral R, resolução espectral 0,63 - 0,69µm. bandas espectrais NIR, resolução espectral 0,77 - 0,89µm. Resolução radiométrica corresponde a 10 bits; permitiu capturar detalhes finos da vegetação e dos objetos terrestres, melhorando a capacidade dos algoritmos para distinguir diferentes classes. As imagens obtidas através da composição e fusão de 4 bandas espectrais, possibilitaram a geração de uma imagem RGB com infravermelho da região de SFX e Altamira e suas fronteiras com outros municípios.

O satélite CBERS-4 representa uma evolução em relação aos satélites CBERS-1, 2 e 2B. Para os CBERS-4, são utilizadas quatro câmeras (Câmera Pancromática e Multiespectral - PAN, Câmera Multiespectral Regular - MUX, Imageador Multiespectral e Termal - IRS, e Câmera de Campo Largo - WFI) com desempenhos geométricos e radiométricos melhorados. A câmera PAN possui uma faixa de imageamento de 60 Km. Essa faixa estreita faz com que a PAN tenha um tempo de revisita no equador prejudicado em relação aos outros imageadores. Como importante consequência está o fato de que o padrão orbital com ciclo de 26 dias não lhe permite cobrir totalmente o equador, por exemplo. Para sanar esse inconveniente, esse imageador é dotado de um espelho de visada lateral, desenvolvido para cobrir faixas adjacentes ao percurso subsatélite. Esta câmera apresenta a melhor resolução espacial a bordo dos CBERS-4, com 5 metros na banda pancromática e 10 metros nas multiespectrais.

A câmera MUX é feita no Brasil e sua principal função é manter a continuidade dos imageamentos feitos pelos três CBERS anteriores. É o sensor que assegura o recobrimento global pelo CBERS numa resolução espacial padrão a cada 26 dias. Com um campo de visado estreito, há pouca alteração no tamanho do pixel nas bordas da imagem. As aplicações dessa câmera são as desenvolvidas para os satélites que possuem câmeras nessa classe de resolução (20 metros). Ao contrário da sua congênere a bordo dos CBERS anteriores, a MUX não possui capacidade de visada lateral. O IRS (Imageador Multiespectral e Termal) é um sensor de varredura mecânica. Sua resolução espacial é de 40 metros nas bandas pancromática e do SWIR (infravermelho de ondas curtas) e para 80 metros na banda termal. Com seu campo de visada de 120 Km, acompanha o ciclo de 26 dias para fazer o recobrimento global.

Referente as características do arquivo de dados. O primeiro passo consistiu em coletar um conjunto de dados de treinamento que contém exemplos rotulados. Cada exemplo consistiu em analisar as várias características (ou atributos) e um rótulo que indica a classe (no caso de classificação).

Durante o pré-processamento foi utilizado técnicas de Data augmentation, transformações que codificam muitas das invariâncias que apresentam desafios para as tarefas de reconhecimento de uma imagem.[228]. Processo importante quando foi preciso obter mais dados e tentar melhorar os resultados. Uma análise minuciosa foi realizada considerando as vantagens e desvantagens de cada uma das técnicas. A correção atmosférica, correção radiometria, fusão de bandas, normalização e filtragem de ruído. A fusão de imagens multi-temporais ou uso de imagens de radar são menos afetadas por cobertura de nuvens. Esta etapa tratou imagens com nuvens e sombras, contribuiu com a disponibilização de dados de qualidade e reduziu o impacto de fatores indesejados, como ruídos, distorções geométricas, variações atmosféricas.

Uso de técnicas de aumento de dados: O aumento de dados, técnica em que o conjunto de treinamento foi aumentado com versões modificadas das imagens originais; rotação, espelhamento, mudanças de escala e outras transformações que preservam as características das classes. Contribuiu com a capacidade da rede de generalizar e lidar com variações nas imagens de satélite.

Pós-processamento e refinamento dos resultados: Após a classificação inicial, técnicas de pós-processamento foram aplicadas para melhorar a precisão dos resultados. Operações de filtragem espacial, eliminação de ruído, preenchimento de lacunas e fusão com outras informações auxiliares para aprimorar a classificação.

Aprendizado semi-supervisionado e transferência de aprendizado: Para expandir o conjunto de treinamento e melhorar a precisão da classificação foi analisado o conjunto de treinamento; Técnicas de aprendizado semi-supervisionado foram aplicadas para utilizar dados não rotulados adicionais e melhorar a precisão da classificação.

A rotulagem manual de grandes conjuntos de dados foi demorada; A transferência de aprendizado foi explorada, uma rede pré-treinada em uma tarefa relacionada foi usada como ponto de partida e fine tuning foi realizado com o conjunto de dados de interesse O uso de técnicas de agrupamento ou segmentação de imagens não rotuladas foram utilizadas para identificar regiões semelhantes e, em seguida, atribuir rótulos a essas regiões com base em informações das regiões vizinhas rotuladas.

Avaliação e ajuste: para identificar erros comuns e padrões de classificação incorretos foi realizado uma avaliação cuidadosa dos resultados da classificação. Com base nessa avaliação, ajustes nos algoritmos, nos parâmetros de classificação ou nas estratégias de pré e pós-processamento foram feitos para melhorar a precisão e a qualidade dos resultados.

A combinação de várias dessas estratégias contribuiu com a geração de resultados precisos. O desempenho pode variar dependendo do conjunto de dados e das características específicas das imagens. A classificação de imagens de satélite é uma tarefa complexa e os resultados podem variar dependendo das condições específicas da região Amazônica Brasileira. A experimentação e a iteração foram fundamentais para ajustar e aprimorar os métodos conforme necessário. Por isso, diversos algoritmos foram utilizados para aprimorar a classificação de imagens de satélite.

Considerando as peculiaridades da região Amazônica Brasileira foram utilizadas algumas estratégias: o processo de classificação de imagens de satélite consistiu em aumentar o tamanho e a qualidade do conjunto de treinamento: Foi selecionado um conjunto de treinamento diversificado e representativo da região Amazônica Brasileira: Imagens que abrangem diferentes tipos de cobertura terrestre, florestas primárias, áreas desmatadas, áreas urbanas, áreas de mineração , áreas de proteção ambiental, (imagens representativas de todas as classes de interesse); amostras adequadas de cada classe de interesse para garantir que a algoritmos utilizados possam aprender/reconhecer características distintivas de cada uma. A cada pixel ou região foi utilizado rótulos de qualidade.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Redes Neurais Convolucionais (RNC): As RNC têm sido amplamente utilizadas na classificação de imagens de satélite e continuam evoluindo com arquiteturas mais avançadas, como redes residuais (ResNet), redes convolucionais profundas (Deep RNC) e redes neurais

convolucionais recorrentes (RNC). Essas arquiteturas são projetadas para aprender características mais complexas e capturar relações de longo alcance nas imagens de satélite.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Redes Neurais Generativas Adversariais (GANs). As GANs são um tipo de rede neural que consiste em um gerador e um discriminador que competem entre si. As GANs têm sido aplicadas na geração de imagens sintéticas de alta qualidade que se assemelham às imagens de satélite reais. Essas imagens geradas podem ser usadas para expandir conjuntos de treinamento e melhorar a capacidade de generalização dos modelos de classificação.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Transferência de Aprendizado. A transferência de aprendizado é uma técnica em que um modelo pré-treinado em uma tarefa relacionada é utilizado como ponto de partida para uma nova tarefa. No caso da classificação de imagens de satélite, pode-se utilizar um modelo pré-treinado em um conjunto de dados de imagens de satélite semelhante, como uma região geográfica próxima, e, em seguida, ajustá-lo para o conjunto de dados da região alvo. Isso ajuda a aproveitar o conhecimento prévio e acelerar o processo de treinamento.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Aprendizado não supervisionado. Técnicas de aprendizado não supervisionado, como agrupamento e autoencoder, estão sendo exploradas para a classificação de imagens de satélite. Essas abordagens permitem identificar padrões e agrupamentos nas imagens sem a necessidade de rótulos, o que pode ser útil quando a disponibilidade de dados rotulados é limitada.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Aprendizado por reforço. O aprendizado por reforço pode melhorar a classificação de imagens de satélite, especialmente em cenários de mudanças temporais. Nesse caso, um agente de aprendizado por reforço pode ser treinado para tomar ações sequenciais em diferentes imagens de satélite, considerando as recompensas e objetivos específicos da classificação.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Extração de características: Extração de características relevantes das regiões segmentadas. Isso pode incluir características espectrais, como a média e o desvio padrão dos valores de pixel nas diferentes bandas espectrais, bem como características de textura, como Haralick e Gabor.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Fusão de dados multi-fonte: A fusão de dados de várias fontes, como imagens de satélite, dados lidar e dados SAR, pode melhorar a precisão da classificação. A combinação de diferentes fontes de

dados pode fornecer informações complementares e melhorar a capacidade de discriminação das classes.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Técnicas de atenção e interpretabilidade: As técnicas de atenção estão sendo aplicadas nas RNC para melhorar a capacidade de localização e interpretabilidade dos resultados da classificação. Essas técnicas ajudam a identificar quais regiões das imagens são mais relevantes para a classificação e fornecem insights sobre o processo de tomada de decisão da rede neural.

Algoritmos que podem aprimorar a classificação de imagens de satélite: Técnicas de atenção e interpretabilidade: No processo de interpretação utiliza-se bandas espectrais sensíveis, à contribuição da vegetação, gerando padrões de cobertura da terra intuitivos à detecção pelo olho humano, para auxílio na identificação dos padrões observados. As bandas AWiFS 5, 4 e 3, correspondentes às regiões do espectro eletromagnético do infravermelho médio (1,55-1,70 µm), infravermelho próximo (0,77-0,86 µm) e vermelho (0,62-0,68 µm), são associadas respectivamente aos canais vermelho, verde e azul. O sensor WFI, as bandas espectrais utilizadas, também sensíveis à contribuição da vegetação, correspondem ao vermelho (0,63-0,69 µm), infravermelho próximo (0,77-0,89 µm) e ao verde (0,52-0,59µm).70

Algoritmos que podem aprimorar a classificação de imagens de satélite: Técnicas de atenção e interpretabilidade: Nas imagens de satélite são aplicados algoritmos de remoção de nuvens (Cloud detector). Após a geração dos mosaicos anuais foram coletadas amostras de treinamento e validação para as seguintes classes de uso e cobertura: mineração, áreas de proteção ambiental, corte raso e queimadas.

Ferramenta utilizada para a classificação de imagens de satélite: O QGIS, sistema de informações geográficas de código aberto que possui vários plugins e recursos para processamento e análise de imagens de satélite. Embora o QGIS não seja uma ferramenta específica para classificação de imagens de satélite, foi usado, pois, oferece suporte a várias extensões e plugins, como o Semi-Automatic Classification Plugin (SCP), que permitem realizar tarefas de segmentação e classificação. Ferramenta utilizada para a classificação de imagens de satélite: Dzetsaka[189] Na ferramenta "Dzetsaka[189]", criou-se uma camada vetorial com um campo de classificação que foi mapeado para a banda de satélite. Cada classificação correspondeu a um recorte da área de interesse a qual a classificação corresponde. Na pratica, foi elaborado um modelo para classificar uma grande área com base em pequenas amostras da própria imagem.

Ferramenta utilizada para a classificação de imagens de satélite: Python: Python com bibliotecas de processamento de imagem: Bibliotecas utilizadas: scikit-learn, TensorFlow,

Keras e PyTorch forneceram recursos para implementar algoritmos de classificação de imagens de satélite usando técnicas de aprendizado de máquina.

Ferramenta utilizada para a classificação de imagens de satélite: Google Earth Engine: O Google Earth Engine é uma plataforma baseada em nuvem que permite acessar e processar grandes conjuntos de dados de imagens de satélite. Oferece uma biblioteca extensa de algoritmos para análise e classificação de imagens, bem como recursos para desenvolver e implementar scripts personalizados usando JavaScript ou Python.

Técnica utilizada para o pré-processamento de imagens de satélite: para aprimorar a precisão da classificação de imagens de satélite, considerando as peculiaridades da região Amazônica Brasileira. A Correção Radiométrica foi realizada para normalizar as diferenças na intensidade da radiação, entre diferentes imagens, em diferentes bandas espectrais (mesma imagem). Isso envolveu a aplicação de correções para eliminar efeitos indesejados observados durante a analise realizada (como o efeito do ângulo de visão, o efeito da atmosfera e variações de iluminação solar). O algoritmo de Subtração de objetos escuros (DOS) foi usado para corrigir o viés radiométrico nas imagens de satélite. Esse método analisou/supôs que a presença de objetos escuros na imagem tem um valor de pixel próximo de zero, mesmo na ausência de iluminação direta. O algoritmo subtraiu uma estimativa do nível de pixel escuro para corrigir o viés radiométrico. O algoritmo Calibração Empírica de Linha (ELC) foi usado para calibrar imagens de satélite usando dados espectrais de campo. Realizou uma correção espectral que relacionou valores de pixel da imagem com a radiação medida em campo. Contribuiu com a eliminação de influencias que o sensor poderia ter sofrido, e a obtenção de valores radiométricos mais precisos; A correção atmosférica foi aplicada para remover, reduzir os efeitos da atmosfera na imagem de satélite. Técnicas como o Modelo de Transferência Radiativa (RTM)[230] ou modelos empiricamente ajustados foram usados para estimar e corrigir esses efeitos.[225]O algoritmo de correção atmosférica usado, método rápido e eficiente para a correção atmosférica. A fusão de bandas envolveu a combinação de diferentes bandas espectrais da imagem em uma única imagem composta, fornecendo uma visão mais completa e facilitando a identificação de características. O filtro de mediana foi utilizado para auxiliar no processo de filtragem espacial para reduzir ruídos em imagens de satélite e preservar os detalhes de borda. Realizou a substituição de cada valor de pixel pela mediana dos valores na vizinhança desse pixel. O algoritmo de Filtragem de Suavização Gaussiana realizou a suavização da imagem, removeu ruídos de alta frequência. Os algoritmos foram executados com os mesmos dados de treinamento, de testes e de validação, no software QGIS.

3.6. Medidas de Desempenho

É fundamental a testagem de diferentes algoritmos quando trabalhamos com modelos de classificação. É importante utilizarmos métricas que avaliem o desempenho de cada um dos modelos para que se escolha o melhor entre eles. Medidas de desempenho que tem como objetivo avaliar a qualidade dos preditores de classificação, com base em fórmulas matemáticas e estatísticas.

3.6.1. Métricas de Avaliação

A literatura apresenta métricas de avaliação adequadas a cada tipo de algoritmos de aprendizado de máquina para avaliar resultados, com o intuito de mensurar o quanto um modelo gerado satisfaz o problema em questão. A forma mais básica de se avaliar um modelo de classificação é através da matriz de confusão, por meio desta matriz é possível visualizar as taxas de acerto e erro do modelo.

A matriz de confusão apresenta o desempenho do modelo, quatro classes: VERDADEIRO POSITIVO: casos em que o valor real é positivo e o modelo também prediz que ele é positivo; VERDADEIRO NEGATIVO: casos em que o valor real é negativo e o modelo também prediz que é negativo; FALSO POSITIVO: casos em que o valor real é negativo e o modelo prediz positivo; FALSO NEGATIVO: casos em que o valor real é positivo e o modelo prediz negativo.

A matriz de confusão consiste basicamente em uma tabela que apresenta o número de predições corretas e incorretas categorizadas por tipo de resposta, onde cada coluna representa as instâncias de uma classe prevista e as linhas representam as classes reais. Existem quatro tipos de classificação na matriz de confusão: Verdadeiros Positivos (VP): São os casos em que o modelo classificou corretamente como positivo; Falsos Positivos (FP): São os casos que o modelo classificou incorretamente como positivos, pois eram negativos; Verdadeiros Negativos (VN): São casos em que o modelo classificou corretamente como negativos; Falsos Negativos (FN): São casos em que o modelo classificou incorretamente como negativos, pois eram positivos.

As métricas usadas no trabalho, Acurácia, Precisão, Recall, F-Score e Kappa Score e seus cálculos a partir da matriz de confusão, bem como o objetivo de avaliação de cada uma.[167,198]

Precisão é o percentual de casos classificados como positivos que estão corretos e pode ser utilizado em situações em que os falsos positivos são mais prejudiciais que os falsos negativos.

$$Precisão = \frac{VP}{VP+FP} \qquad (1)$$

VP = Verdadeiro Positivo
FP = Falso Positivo

A precisão é a quantidade de instâncias classificadas corretamente como positivas dividida pelo total de instâncias classificadas como positivas. Um valor alto na métrica Precisão indica um número pequeno de falsos positivos. Quando os segmentos estavam totalmente sobrepostos à referência, o valor de Precisão chega ao máximo. Para contornar este problema, calcula-se o F-Score, correspondente à média harmônica entre as medidas Precision e Recall, levando em consideração tanto os falsos positivos quanto os falsos negativos.

Acurácia é o percentual de instâncias positivas e negativas classificadas corretamente e pode ser calculada através da equação:

$$Acurácia = \frac{VP+VN1}{VP+VN+FP+FN} \qquad (2)$$

VP = Verdadeiro Positivo
VN = Verdadeiro Negativo
FP = Falso Positivo
FN = Falso Negativo

A acurácia mediu quantas instâncias foram classificadas corretamente, independente da classe, por meio da razão entre o que o modelo acertou e a quantidade de instâncias classificadas. equivale à razão entre o número de pixels classificados corretamente e o número total de predições. Acurácia apresenta uma visão geral dos erros, assim como mede o desempenho geral com um único valor numérico. Este valor pode variar de 0 a 1, sendo mais compreensível analiticamente para o público em geral. Assim como a matriz de confusão, a acurácia leva em consideração as mesmas métricas. A métrica Acurácia equivale à razão entre o número de pixels classificados corretamente e o número total de predições. Um valor alto na métrica Precisão indica um número pequeno de falsos positivos.

O Recall é a quantidade de instâncias classificadas corretamente como positivas dividida pela soma de instâncias verdadeiramente positivas com os falsos negativos**.** Um valor alto da métrica Recall indica pouca quantidade de falsos negativos

$$Recall = \frac{VP}{VP+FN} \qquad (3)$$

VP = Verdadeiro Positivo

FN = Falso Negativo

F-Score é a média harmônica entre a precisão e o Recall e pode ser calculada através de uma equação.[146]

$$\mathrm{F-Score} = 2 * \frac{\mathrm{Precisão}*\mathrm{Recall}}{Precisão+Recall} \qquad (4)$$

F-Score avaliou quantitativamente os segmentos gerados. A métrica F-Score, a média harmônica entre Precision e Recall procura fazer o balanço entre estas duas métricas.[199]

O coeficiente KappaScore avaliou o nível de concordância entre o real e o predito em uma tarefa de classificação e indica o quanto as observações se afastam daquelas esperadas.

$$k = \frac{Acurácia - AcuráciaEsperada}{1 - AcuráciaEsperada} \qquad (5)$$

A acurácia esperada é calculada através do somatório da multiplicação entre o total real e o total predito divido pelo total de linhas de cada classe, este somatório é dividido pelo total de linhas novamente, chegando assim ao resultado.

4. Resultados

Esta etapa apresenta resultados considerando uma análise comparativa dos modelos usados, GeoKNN, GeoRF, GeoRNC. Análises de Inteligência Artificial, Geoprocessamento e Sensoriamento Remoto utilizado para realizar o processamento de imagens de satélite, analisando o desmatamento na região amazônica Brasileira.

4.1. Análise de índices de Desmatamento

O Estado do Pará foi o território que apresentou o maior índice de desmatamento acumulado nas últimas dácadas. Altamira, município do Pará, apresentou índice estimado de 9.660 Km^2 para desflorestamento. São Felix do Xingu (PA) apresentou os maiores índices de desmatamento, estimado em 14.185 Km^2 de área desmatada. A Figura 5 apresenta a taxa de desmatamento acumulado, no periodo de 2001 a 2022.

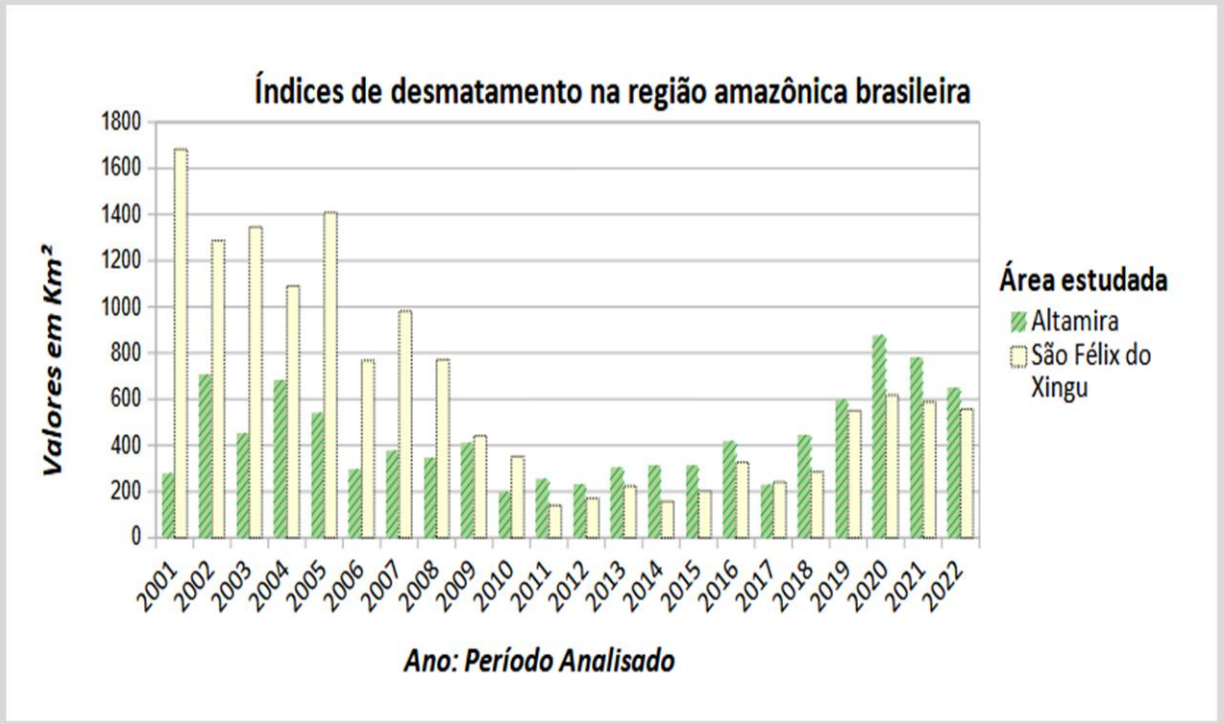

Figura 5 - Taxa de desmatamento/desflorestamento acumulado
Fonte: INPE[43]

lEm 2022, estimou-se uma redução de 16% em Altamira e 5% em São Félix do Xingu em relação ao ano anterior (2021), que apresentaram taxa de desmatamento respectivamente de 780 Km^2 e 587 Km^2. Esta redução representa a eliminação de 1.207 Km^2 de floresta. No ano de 2014 foi computado uma taxa de desmatamento equivalente a 5.012 Km^2, redução de

15% em relação às taxas do ano anterior (5.891 Km²). No ano de 2015, estimou-se um aumento de 16% em relação ao ano anterior. Este aumento representa a eliminaçãode 5.831 Km² de floresta.[197]

Em 2018 o município de Altamira desmatou 435,0 Km^2 de território e em 2019 desmatou 575,4 Km^2 de território. O município de São Felix do Xingu apresentou em 2018, índice de desmatamento 293,7 Km^2 de território desmatado. E em 2019 desmatou 543,9 Km^2 de território.

O Plano de Ação de Prevenção e Controle do Desmatamento na Amazônia estimou reduzir o desmatamento até o ano de 2020,[200] na região Amazônica Legal. Mas, os resultados deste plano não se mostraram suficientes para alcançar a meta estipulada para 2020. A partir de 2013 o desmatamento voltou a crescer; em 2018 registrou 7.536 Km^2. No ano de 2019 atingiu quase 10.000 Km^2.

A situação agravou-se ao longo de 2019, com elevação de 30%, em contraste com o ano anterior, atingindo a marca de 9.762 Km^2.[201] Nos anos de 2018 e 2019 ocorreram um aumento expressivo no índice de desmatamento e focos de queimadas, na região Amazônica Brasileira.

O Desmatamento da Amazônia em abril de 2020 foi o maior, considerando os últimos dez anos.[202]Entre as medidas adotadas neste período, destacam-se:[201] alteração das políticas públicas necessárias à prevenção e ao controle do desmatamento.[203] Entre os atos podem-se listar: (i) a extinção da Secretaria de Mudanças do Clima e Florestas do MMA, (ii) a extinção da Subsecretaria Geral de Meio Ambiente, Energia e Ciência e Tecnologia do Ministério das Relações Exteriores, (iii) a exoneração de inúmerossuperintendentes estaduais do Instituto Brasileiro do Meio Ambiente (IBAMA);[202] (iv) a redução do número de membros do Conselho Nacional do Meio Ambiente, outros.

Em agosto de 2021 foi divulgado boletim de desmatamento do IMAZON, o qual averiguou que “em agosto de 2021, o SAD detectou 1.606 quilômetros quadrados de desmatamento na Amazônia Brasileira, um aumento de 7% em relação a agosto de 2020, quando o desmatamento somou 1.499 quilômetros quadrados.” [23]

Ao longo de quatorze anos, o Plano de Ação de Prevenção e Controle do Desmatamento na Amazônia (PPCDAM) obteve resultados satisfatórios. A partir de 2008 houve uma redução drástica do desmatamento amazônico.[200] O PPCDAM produziu resultados notáveis: entre 2004e 2012, o desmatamento caiu mais de 80%, passando para menos de 4.600 Km^2. O desmatamento foi menor nas áreas indígenas demarcadas.[204] Entre as medidas adotadas neste período, destacam-se: O Decreto numero 6.321, de 21 dedezembro de 2007, que institui lista de municípios, selecionados em razão das altas taxas de desmatamento registradas.[205]

Restrições administrativas e econômicas significativas, entre as quais se destacam,

proibição de emissão de novas autorizações de desmatamento em dimensãosuperior a 5 hectares; possibilidade de recadastramento de imóveis rurais pelo Instituto Nacional de Colonização e Reforma Agrária (Incra); Embargo de áreas desmatadas ilegalmente; intensificação da fiscalização; publicação pelo Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis (Ibama) da lista de imóveis com cobertura vegetal monitorada/embargados; proibição de concessão de crédito por agências oficiais para atividades agropecuárias ou florestais em imóvel rural que descumpra embargo.[206]

Altamira e SFX lideram, desde 2012, a lista dos municípios prioritários do MMA com as maiores taxas de incremento de desmatamento no Estado do Pará.[207] A área estuda integrara a lista de municípios prioritários do Ministério do Meio Ambiente (MMA) São Félix do Xingu, e Altamira.[211] Os critérios para inclusão na lista do MMA: a) área total de floresta desmatada no território do município; b) área total de florestadesmatada nos últimos três anos; c) aumento da taxa de desmatamento em pelo menos três, dos últimos cinco anos.[205]A instituição da Lista de Municípios Prioritários do MMA, constituída de municípios com altas taxas de desmatamento, decorreu do Plano de Ação de Prevenção e Controle do Desmatamento na Amazônia (PPCDAM).[205]

Apesar do histórico de altas taxas de desmatamento, houve uma redução neste índice no Estado do Pará desde 2005 até 2014, quando volta a aumentar.[207] Mas, uma redução em 2017, na área analisada foi observado: Altamira desmatou 409,5 Km^2 em 2016 e em 2017 224,8 Km^2de território desmatado. Em São Felix do Xingu também ocorreu redução de 314,9 Km^2 (2016) para 239,9 Km^2 (2017).

4.2. Resultados KNN, RF e RNC

Os processos de desmatamento acarretam diversos impactos Socioambientais e econômicos, como: fragmentação florestal; redução da evapotranspiração; emissões de gases de efeito estufa; redução da biodiversidade; alteração de microclimas; mortalidade de árvores; aumento do risco de incêndios florestais.[220]Cerca de 70% do desmatamento esperado, para o ano de 2022, foi detectado pelo SAD. 85% dos alertas de desmatamento concentraram-se em uma distância de até 4 Km do local previsto. Há 16 anos, o estado do Pará liderou o ranking de desmatamento na Amazônia, perdendo um total de 58.456,00 Km² de floresta nativa[195]. Em 2022, 557 Km² foram desmatados em SFX, ocupando a quinta posição no ranking de alertas de desmatamentos do SAD em 2022.

Os algoritmos KNN, RF e a RNC foram utilizados para gerar o aprendizado de parâmetros de identificação das classes de áreas desflorestadas (considerando corte raso e queimadas), áreas de mineração, áreas de proteção Ambiental. Os métodos usados classificaram as imagens de satélite de longo alcance sobre a área de estudo. A estratégia realizou um experimento em um grande banco de dados, que foi utilizado para treinar a máquina, de modo a extrapolar o treinamento e ser capaz de realizar as tarefas diante de uma nova informação. Assim, na presença de uma nova informação, uma nova imagem, o algoritmo foi capaz de classificar a presença do desmatamento ou não com base na presença ou não dessas características aprendidas. Considerando rótulos mais específicos das classes: CORTE RASO, QUEIMADAS, MINERAÇÃO e ÁREAS DE PROTEÇÃO AMBIENTAL. Então os algoritmos, com base nesse banco de dados, identificaram as características em comum entre as imagens de cada conjunto. A cada nova informação, nova imagem, o algoritmo foi capaz de classificar a presença do desmatamento ou não com base na presença ou não dessas características aprendidas, com base no banco de dados classificou as classes Corte raso, Queimada, Mineração, Área de Proteção Ambiental. A rede neural de convolução utilizou um conjunto dessas camadas para encontrar padrões em comum em partes de uma imagem, para encontrar pontos de contraste, identificáveis em mais de um caso de imagens semelhantes, mas não necessariamente idênticas.

4.2.1. Resultados Random Forest (RF)

O RF obteve resultado bom para as classes analisadas. Porém, este classificador não obteve bons resultados gerais, se comparado aos outros métodos, de forma que o melhor resultado foi com a base de dados filtrada com máscara 3x3, atingindo uma acurácia de 96,97% e coeficiente kappa de 76,92%, conforme Figura 6.

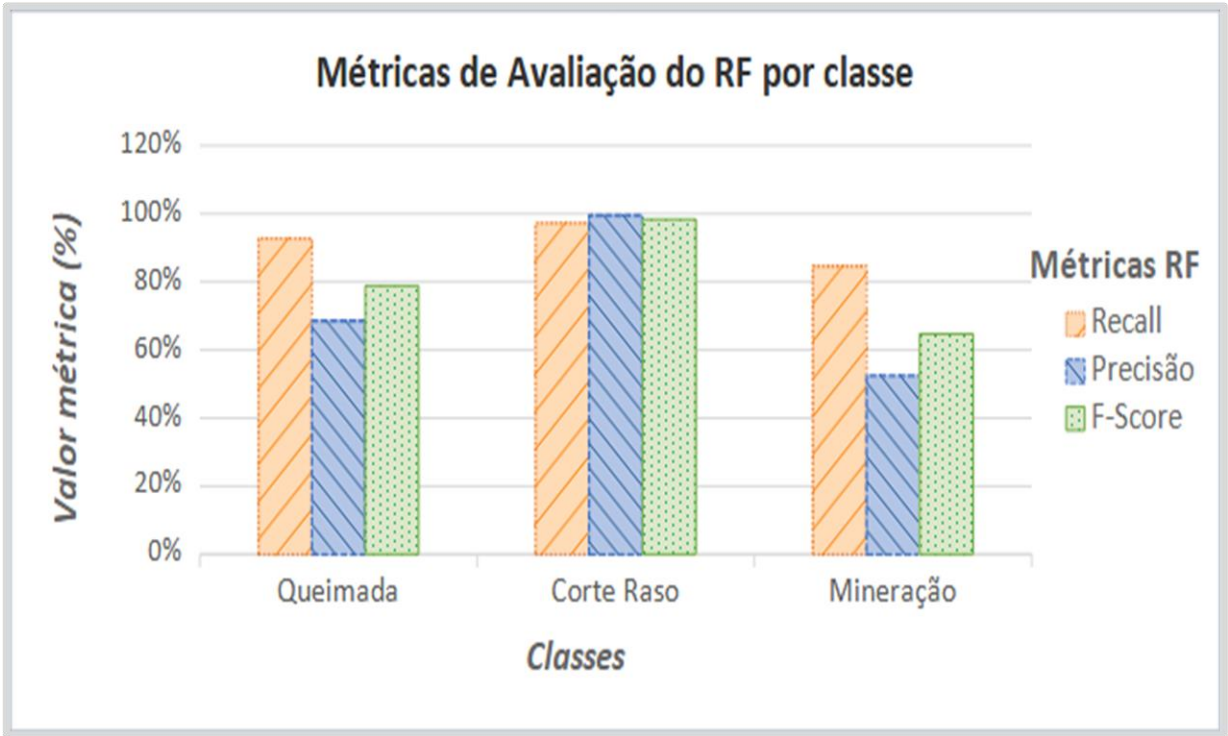

Figura 6 - Resultados RF
Fonte: Autor

Com a aplicação dos filtros, esse algoritmo classificou muitos pixels erroneamente como Corte Raso, em vez de Queimada, fato que pode ser percebido pelo crescimento na precisão e decaimento da especificidade, na classe Corte Raso, representado. A métrica F-score apresenta, que, a classe Corte Raso foi melhor identificada, e a classe Mineração foi a pior.

4.2.2. Resultados KNN

Os resultados do KNN foram similares ao RF, considerando a classificação dos pixels das classes (Queimadas, corte raso, mineração, áreas de proteção Ambiental). Pequenas diferenças foram notadas, margem de +3 a -3 em acertos em todas as classes em comparação com o algoritmo RF. No entanto, essa diferença não se refletiu de maneira significativa nas métricas, apresentando 96,99% de acurácia e um melhor coeficiente kappa de 77,12%. As métricas Precisão, Especificidade e F-score apresentam que a classe Corte Raso foi melhor identificada, e a classe Mineração foi a pior (Figura 7).

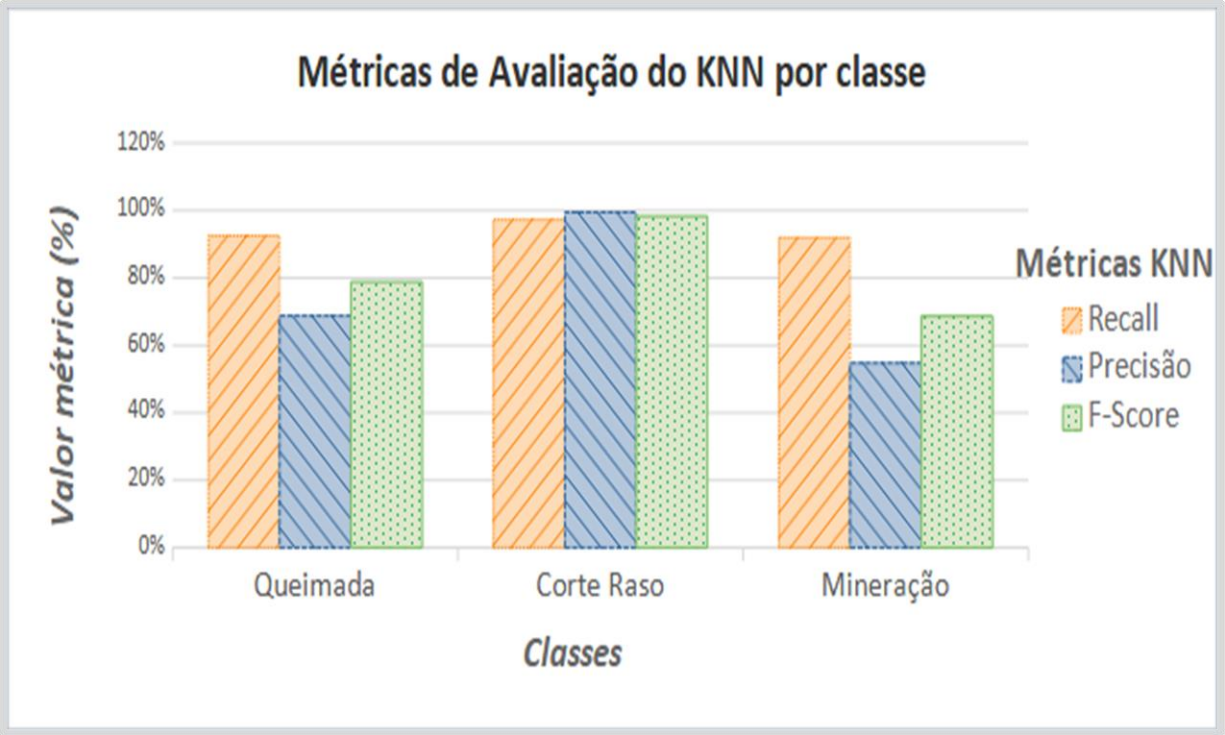

Figura 7 - Resultados KNN
Fonte: Autor

4.2.3. Resultados com RNC

O RNC apresentou o melhor desempenho, comparado aos outros métodos, considerando a classificação dos pixels das classes (Queimadas, corte raso, mineração, área de proteção Ambiental). Os valores de precisão, especificidade e f-score para os pixels de mineração e queimada foram maiores em relação aos outros algoritmos, mostrando ser melhor para identificar essas classes. A classe Corte Raso segue sendo a melhor classe identificada, Figura 8.

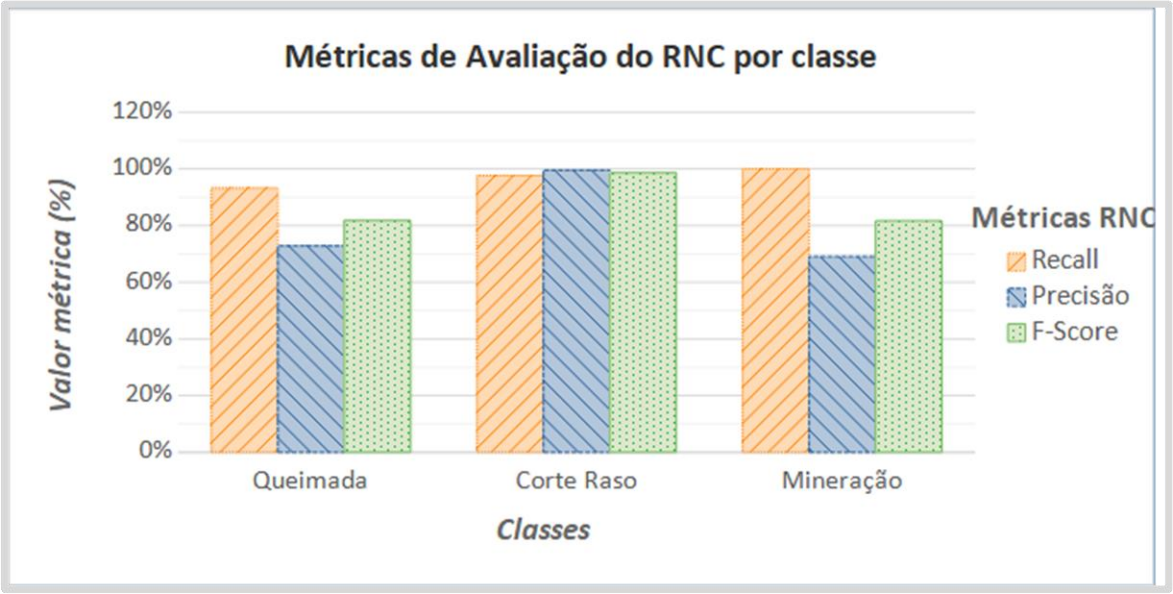

Figura 8 - Resultados RNC
Fonte: Autor

Considerando os algoritmos utilizados, as regiões com Área de Proteção Ambiental tiveram uma área segmentada maior do que a esperada, informando que os modelos classificaram alguns pixels erroneamente, inicialmente, como pertencentes a áreas verdes, que existem com grande extensão nesta região, fato esse que corrobora com a queda na precisão e aumento da sensibilidade observadas em alguns gráficos. Esse tipo de região teve a sua área reduzida conforme maior o tamanho da máscara utilizada no filtro de pré-processamento, indicando que muitos pixels pertencentes a MINERAÇÃO foram classificados incorretamente. Dessa forma, foi possível identificar que a aplicação do filtro com tamanho de máscara maiores que 3 não se provou muito interessante para as imagens selecionadas, devido à resolução espacial grande. Por outro lado, a aplicação dos filtros com máscara de tamanho 3x3 se mostrou promissora para a classificação dos pixels de CORTE RASO, conforme os valores de Precisão e F-Score apresentados no grafico.

4.3. Comparação dos resultados das simulações

A Tabela 1 contém o agrupamento dos resultados (amostra) das matrizes de confusão para os modelos KNN, RF e RNC exportados por meio de algoritmos em linguagem python, onde as colunas são as predições e as linhas a classificação real. Ao lado temos as métricas de avaliação por classe calculadas a partir dos dados da matriz.

Tabela 1 - Matriz de confusão RF, KNN e RNC

Matriz de Confusão do KNN				**Métricas de Avaliação por Classe**		
Classe	**Queimada**	**Corte Raso**	**Mineração**	**Recall**	**Precisão**	**F-Score**
Queimada	1024	82	1	92,5%	68,8%	78,9%
Corte Raso	465	17294	18	97,3%	99,5%	98,4%
Mineração	0	2	23	92,0%	54,8%	68,7%

Matriz de Confusão do RF				**Métricas de Avaliação por Classe**		
Classe	**Queimada**	**Corte Raso**	**Mineração**	**Recall**	**Precisão**	**F-Score**
Queimada	1021	80	0	92,7%	68,6%	78,8%
Corte Raso	468	17294	20	97,3%	99,5%	98,4%
Mineração	0	4	22	84,6%	52,4%	64,7%

Matriz de Confusão do RNC				**Métricas de Avaliação por Classe**		
Classe	**Queimada**	**Corte Raso**	**Mineração**	**Recall**	**Precisão**	**F-Score**
Queimada	1084	79	0	93,2%	72,8%	81,7%
Corte Raso	405	17299	13	97,6%	99,5%	98,6%
Mineração	0	0	29	100,0%	69,0%	81,7%

A matriz de confusão apresenta informações relevantes sobre os acertos e os erros com base nos dados de treinamento, considerando as diferentes classes, queimada, corte raso e mineração. A matriz de confusão fornece os dados para avaliar o desempenho dos modelos, permitindo comparar as previsões com os resultados reais e determinar a precisão da classificação das diferentes classes. Esse procedimento permitiu analisar o quanto o modelo aprendeu sobre a classificação das imagens de satélite, considerando os objetivos do estudo.

O valor na posição (Queimada, Queimada), para os algoritmos KNN, RF, RNC: representou a quantidade de classificações, ou seja, Verdadeiros Positivos, o qual corresponde a aproximadamente 93% de recall, ou seja, a quantidade de vezes que o modelo acertou a predição positiva conforme os dados reais. Nesta posição o classificador consegue prever percentagens diferentes para cada algoritmo, com 69% de precisão para KNN e RF e 73% para o RNC.

O valor na posição, (Queimada, Corte Raso), para algoritmo KNN, representa a quantidade de classificações Falsos Negativos, ou seja, a quantidade de vezes que o modelo classificou incorretamente um resultado como negativo. No exemplo, o modelo classificou incorretamente 82 casos em que o resultado foi CORTE RASO, sendo que o valor real era QUEIMADA.

O valor na posição, (Queimada, Corte Raso), para o algoritmo RF, representa a quantidade de classificações Falsos Negativos, ou seja, a quantidade de vezes que o modelo classificou incorretamente um resultado como negativo. No exemplo, o modelo classificou incorretamente 80 casos em que o resultado foi CORTE RASO, sendo que o valor real era QUEIMADA.

O valor na posição, (Queimada, Corte Raso), para o algoritmo RNC**,** representa a quantidade de classificações Falsos Negativos, ou seja, a quantidade de vezes que o modelo classificou incorretamente um resultado como negativo. No exemplo, o modelo classificou incorretamente 79 casos em que o resultado foi CORTE RASO, sendo que o valor real era QUEIMADA.

O valor na posição, (Corte Raso, Corte Raso), para os algoritmos KNN, RF, RNC, representou a quantidade de classificações Verdadeiros Positivos, o qual corresponde a 97,3% de recall para os modelos KNN e RF, e 97,6% de recall para o modelo da RNC, ou seja, a quantidade de vezes que o modelo acertou a predição positiva conforme os dados reais. Nesta posição o classificador consegue prever 99,5% de precisão para KNN, RF e RNC.

Detalhe na matriz de confusão ficam com relação aos valores de Falsos Positivos com relação aos valores reais de Corte Raso e a previsões classificadas como Queimada. Temos 465, 468 e 405 itens respectivamente dos modelos KNN, RF e RNC classificados como queimada, porém o valor real é Corte Raso. Esses valores impactaram a redução da precisão dos modelos em classificar áreas queimadas.

O modelo de Rede Neural Convolucional (RNC) apresentou os melhores resultados, considerando a classificação de imagens de satelite dos municipios de Altamira e SFX, comparando com os resultados de KNN e RF (Figura 9).

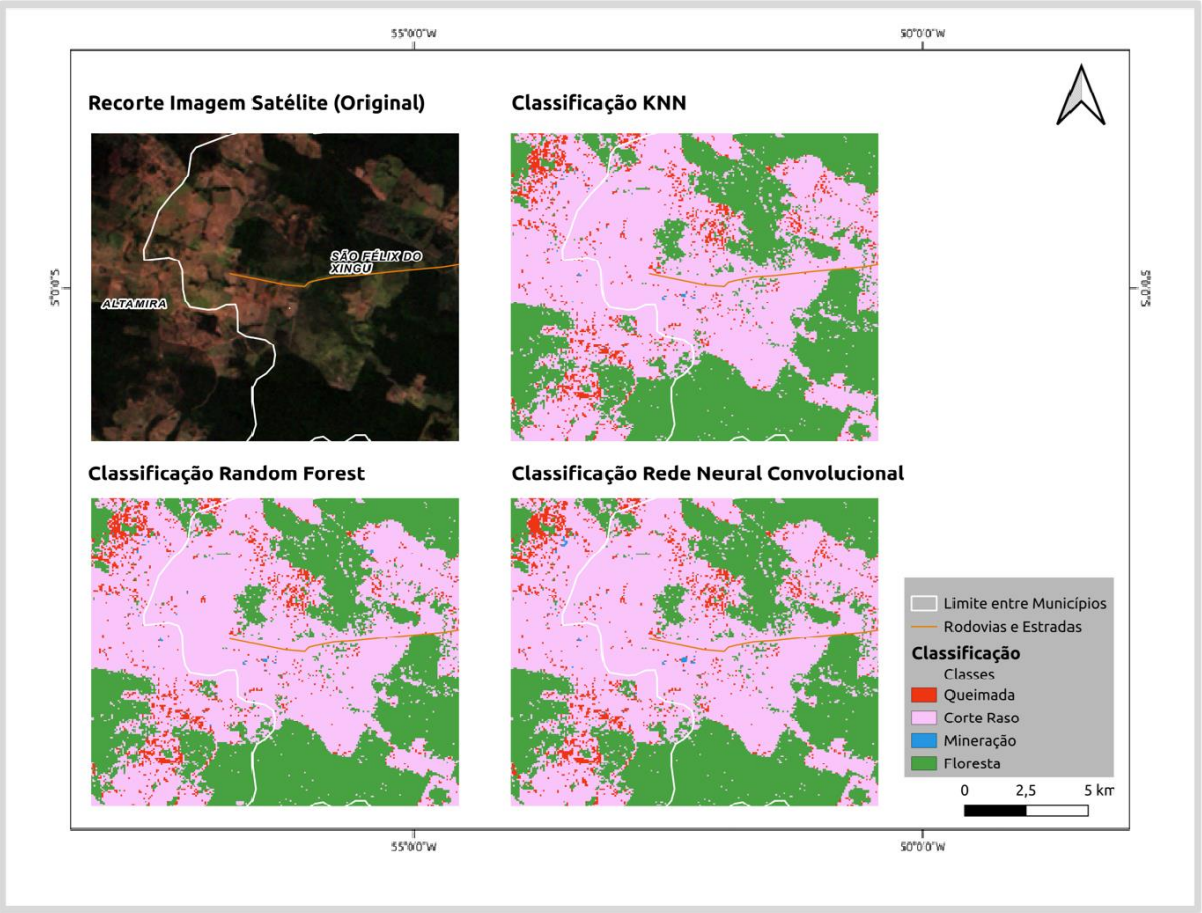

Figura 9 - Comparação dos resultados RNC, KNN, RF
Fonte: Autor

A RNC apresentou complexidade maior no campo de imagens espectrais de satélite. Diferenças de pixels, resoluções e composições de bandas de satélite (modo de captura e distância orbital) interferiram diretamente na classificação e podem limitar o uso do modelo em imagens de satélite no geral.

As imagens processadas apresentaram semelhanças (comportamento da disposição geoespacial dos dados) com relação as áreas afetadas por incêndio e corte raso. Após o processamento, os algoritmos geraram imagens classificadas da região de estudo (Figura 9). A identificação visual da classe Mineração é mínima e imperceptível, pois somando ao acerto presente na matriz de confusão dos 3 algoritmos temos 74 máscaras 3x3 ditas da classe Mineração. De fato, os municípios de estudo não possuem grandes extensões de atividade mineradora, e devido à grande extensão da imagem de satélite utilizada, o aprendizado de máquina ficou prejudicado.

O modelo de Rede Neural Convolucional (RNC) apresentou os melhores resultados para a classificação de imagens de satelite dos municipios de Altamira e SFX, considerando resultados de KNN e RF. Apresentou complexidade maior no campo de imagens espectrais de satélite. Diferenças de pixels, resoluções e composições de bandas de satélite (modo de captura e distância orbital) interferem diretamente na classificação e limitam o uso do modelo em imagens de satélite no geral. Os dados resultantes da classificação utilizando RNC mostram uma diferença dos dados de desflorestamento, no período de 2001 a 2022 e a região estudada, considerando as taxas do PRODES.

O modelo de melhor desempenho foi o RNC, com um desempenho superior, considerando as classes apresentadas, Tabela 2, O modelo RNC apresentou o maior desempenho: Precisão de 99,54%, para corte raso. O KNN apresentou precisão igual a 99,51%, similar ao RF. A classe queimada apresentou precisão inferior, considerando a precisão da classe corte raso. A utilização do Random Forest e KNN resultou em um tempo de execução baixo, de forma que a vantagem na acurácia do KNN não foi considerada relevante, considerando os resultados da RNC.

Tabela 2 - Desempenho RNC, KNN, RF

Classificação	Desempenho do algoritmo		
	KNN (%)	RF (%)	RNC (%)
Área Ardida (Queimadas)	68,77	68,56	72,8
Corte Raso	99,51	99,51	99,54
Mineração	54,76	52,38	69,04
Área de Proteção Ambiental (APA)	98,23	97,98	99,67

A classe APA apresentou o indice de desempenho superior, considerando as classes mineração, Corte Raso, Queimadas. Os algoritmos encontraram padrões em comum em muitas partes das imagens, identificáveis em mais de um caso de imagens semelhantes. Este fato ocorre provavelmente devido as peculiaridades da área estudada, Altamira e São Félix do Xingu, 80% a 85% do território corresponde a áreas de proteção ambiental, seja de origem indígena ou de uso sustentável. A grande extensão dessas áreas facilitou a classificação dos pixels.

A RNC apresentou os melhores índices para as métricas gerais (Figura 10), sendo de 97,4% para Acurácia e 80,4% para KappaScorre (Figua 10). Estudo[131] propuseram seis conceitos de eficiência ao Kappa, ou seja, < 0 – péssima; 0 < k ≤ 0,2 – má; 0,2 < k ≤ 0,4 - razoável; 0,4 < k ≤ 0,6 - boa; 0,6 < k ≤ 0,8 – muto boa; e 0,8 < k ≤ 1,0 – excelente.

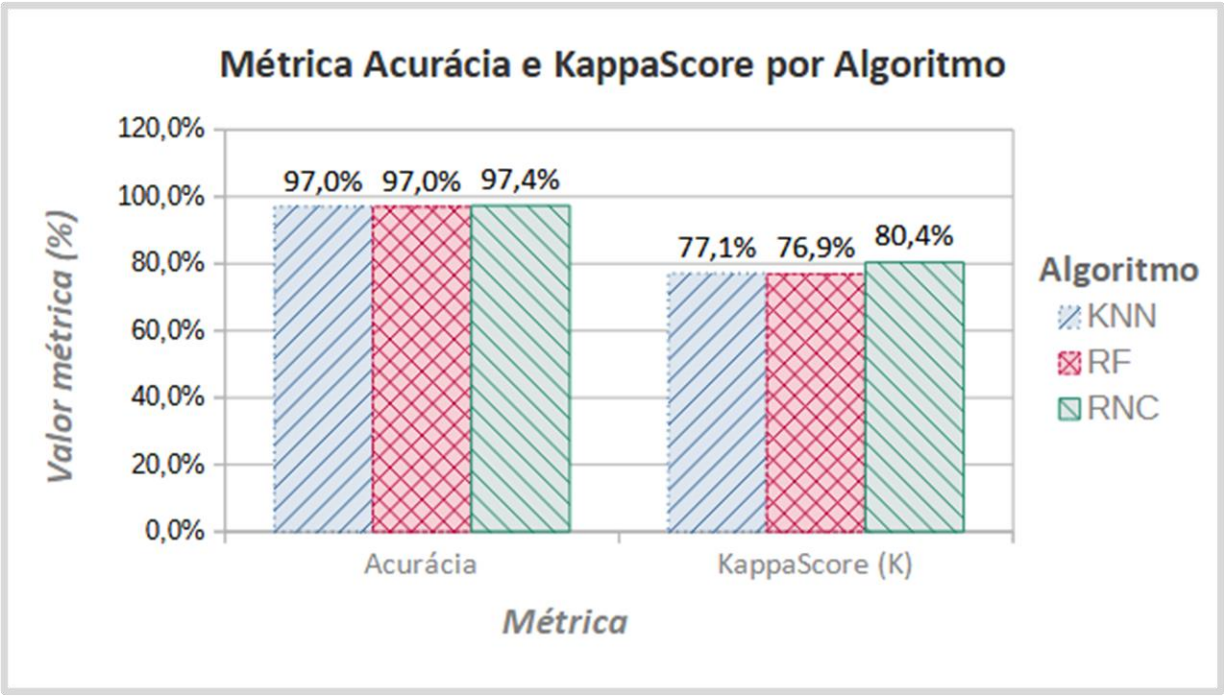

Figura 10 - Resultado Avaliação Geral por Algoritmo
Fonte: Autor

Os dados resultantes da classificação utilizando RNC mostram uma diferença dos dados de desflorestamento, considerando o período de 2001 a 2022 e a região estudada. Segundo o PRODES, a taxa de desflorestamento computada corresponde, aproximadamente, 65.830 Km^2. No entanto, os resultados da classificação utilizando a RNC computou, aproximadamente, 68.035 Km^2.

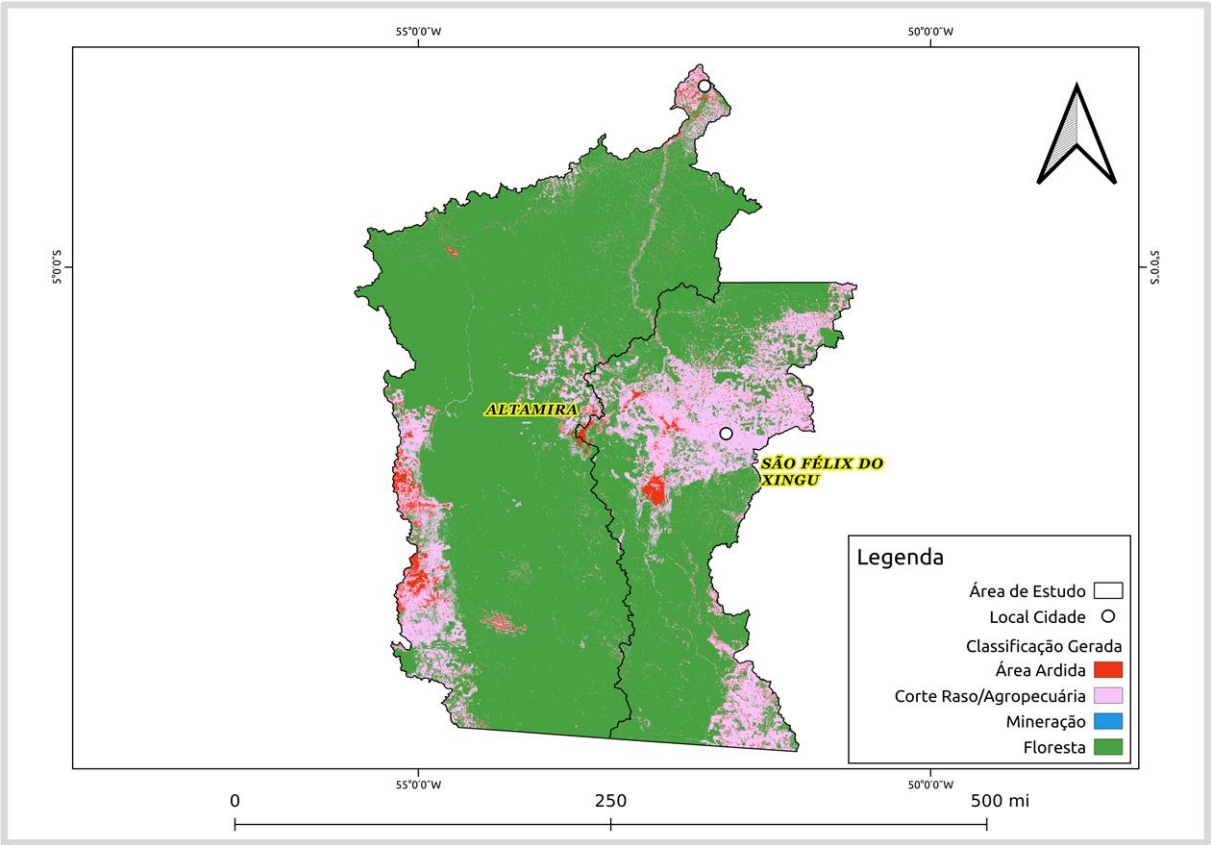

Figura 11 - Resultado Avaliação Geral por Algoritmo
Fonte: INPE[43]

O uso de Inteligência Artificial, o uso de ferramentas e técnicas descritas na metodologia trataram os problemas que geralmente ocorre durante a classificação de imagens de satélite. considerando limite histórico dos dados monitorados pelo PRODES, considerando a natureza geoespacial e temporal dos dados, considerando as classes (Figura 11). A diferença, provavelmente, reflete a antropização (alterações ambientais, sociais ocorridas no espaço geografico) do período anterior a 1988, apresentando uma nova perspectiva dos índices de desmatamento. Este processo ocorre devido a décadas de exploração consecutivas, que causam impactos socioambientais ireversiveis, imperceptiveis e incalculáveis. Os processos de desmatamento e seus impactos ambientais se dão de forma gradativa. Estes processos não devem ser “considerados como representativos apenas do ano em que o desmate final foi constatado”.[233]

A diferença ocorre, pois os programas de monitoramento do desmatamento da região Amazônica Brasileira ainda apresentam algumas desvantagens, considerando, questões tecnológicas, como os tipos de sensores óticos utilizados, características físicas da radiação eletromagnética na faixa do espectro visível, por exemplo, o imageamento ótico é bloqueado pela presença de nuvens; o uso de sistemas ativos de imageamento, que utilizam radar para emitir radiação na faixa do micro-ondas, a aquisição e o processamento de imagens de satélite

com radar de abertura sintética são instrumentos mais eficazes para a aquisição automatizada, mas, o uso ainda demanda etapas de processamento, de modo a tornar a imagem legível para o usuário. Processo que consome bastante tempo e é ainda muito dependente de mão de obra humana, o que aumenta a janela de tempo entre o imageamento e a ação prática tomada com base nas informações dessa imagem.[227]

A Amazônia passará por mudanças irreversíveis, com tendência à savanização, se atingidos 20 a 25% de desmatamento. As consequências de um mundo sem a Amazônia são "catastróficas"para o Brasil e para o planeta. Este processo ocorre devido a décadas de exploração consecutivas, que causam impactos socioambientais ireversiveis, imperceptiveis e incalculáveis.

O método RNC apresentou desempenho superior, considerando os outros métodos (KNN, RF). Devido a este fato, os resultados qualitativos, deste trabalho, apresentam imagens processadas com este método. Pois, visualmente a classificação dos três métodos foram similares. Considerando a interpretação visual: cor, tonalidade, textura, forma e contexto, foi difícil diferencia-las, devido as similaridades observadas, devido a área ser muito extensa.

Considerando os resultados de cada algoritmo, percebeu-se uma dominância do RNC, posteriormente o KNN e em terceiro o Random Forest. O treinamento e os testes foram realizados para cada uma das bases de dados. Para cada algoritmo foram criadas a versão "original", treinada com a base em dados original, e as versões filtradas, identificadas pelo tamanho da máscara utilizada no algoritmo de filtragem.

4.4. Desmatamento em Áreas de proteção Ambiental

A Figura 12 apresenta um experimento contendo os indices de desmatamento na área e os corelaciona com Áreas indígenas e unidades de conservação federais (Área de proteção Ambiental). A área de estudo é uma região de fronteira da Amazônia com a linha do desmatamento que ocorre de forma sistemática. Por isso, essa área é tão disputada por grileiros, madereiros, mineiros/garimpeiros. A interpretação visual confirma que a área estudada possui uma grande porção do seu territorio destinado a áreas de proteção ambiental. Em Altamira e São Félix do Xingu, 80% a 85% do território corresponde a áreas de proteção ambiental, seja de origem indígena ou de uso sustentável.

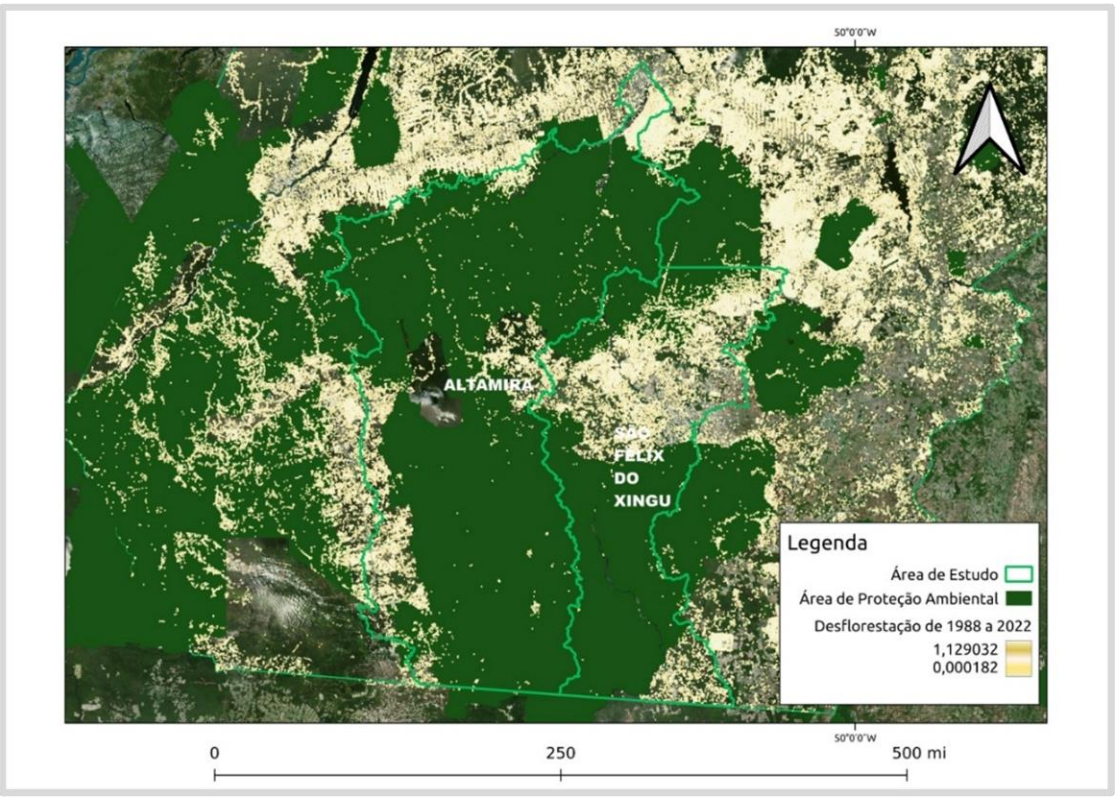

Figura 12 - Análise de desflorestamento/desmatamento e APA
Fonte: INPE[43]

Os dados apresentados (Figura 13) confirma um aumento significativo no índice de desmatamento por corte raso e queimadas. O município de São Félix do Xingu foi ranqueado em 7º lugar em situação crítica no desmatamento florestal, entre dez municípios brasileiros. Em junho de 2019, foram aferidos 39 mil Km² de área desmatada em seu território.[208] Certamente este fato agravará o desequilíbrio de ecossistemas, como a frequência de chuvas nessa região.

-

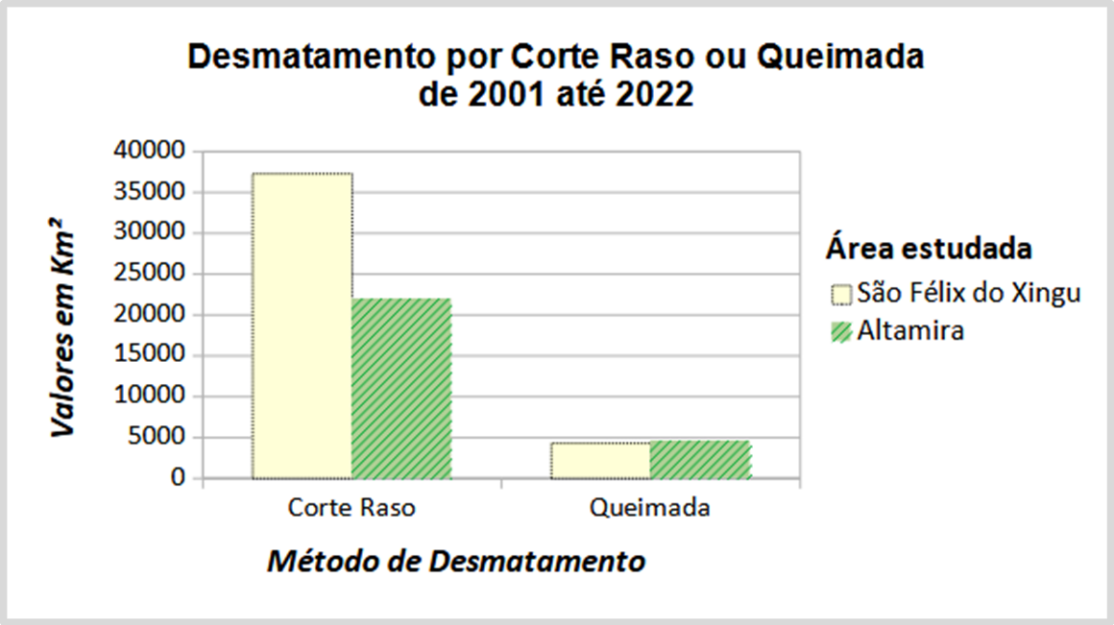

Figura 13 - Desflorestamento, Corte raso e queimada
Fonte: INPE[43]

Os Projetos de Desenvolvimento Sustentável (PDS) Terra Nossa e Itatá, situados no município de Altamira, possuem as maiores taxas de desmatamento entre 2012 e 2015.[209]

O estado do Pará encontra-se submetido a intensas medidas de monitoramento e controle ambiental por parte de diversos órgãos, sobretudo estadual e federal. Mas, Altamira e São Félixdo Xingu continuam liderando, desde 2012, a lista dos municípios com as maiores taxas de incremento de desmatamento no Estado do Pará.[207, 210]

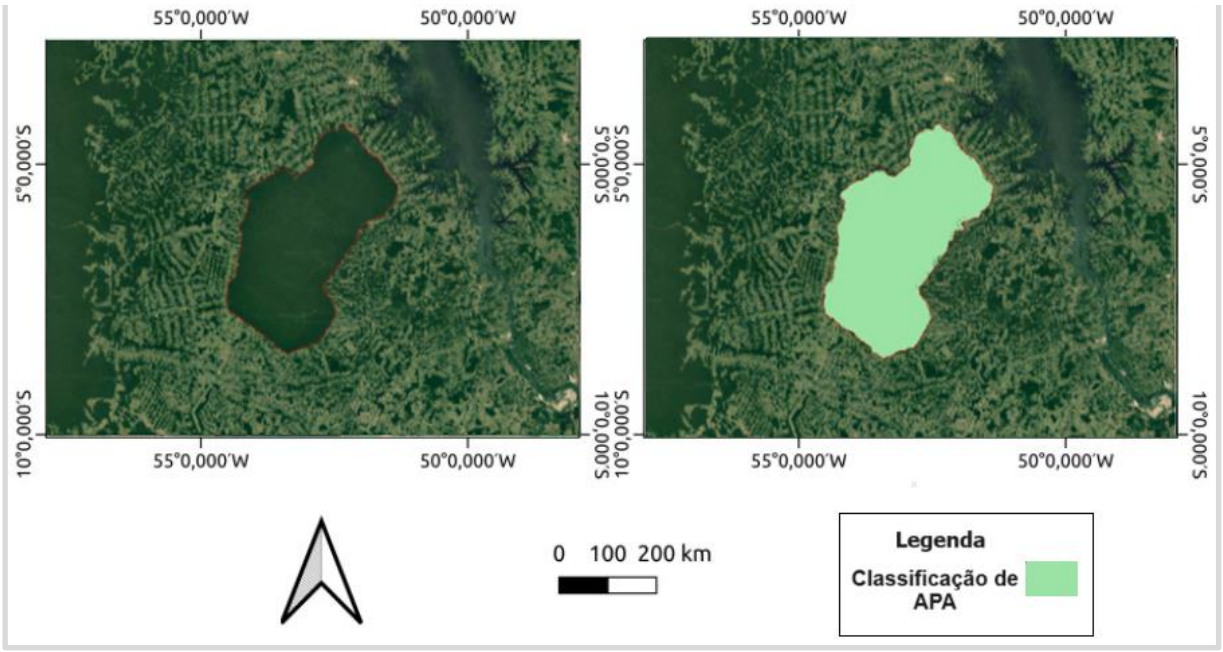

Figura 14 - Classificação de APA
Fonte: INPE43

A Figura 14 apresenta uma APA, dentre as Unidades de Conservação (UCs), duas estiveram, entre as dez, que apresentaram os maiores índices de desmatamento, considerando a Amazônia Brasileira, no período de 2012 a 2015.[43]

A primeira colocada, a APA Trunfo do Xingu e a sexta, a Floresta Nacional Altamira.[70] A ocupação irregular de terras é uma das principais causas de desmatamento na APA Triunfo do Xingu. Esta ocupação decorre da ausência de regularização fundiária e de um plano de manejo, que delimite as áreas destinadas à preservação de recursos ambientais, insuscetíveis de ocupação.

O desmatamento afetou diretamente as comunidades indígenas e tradicionais que dependem das florestas para sua subsistência e preservação cultural. A perda de florestas compromete sua segurança alimentar, recursos naturais e modo de vida.

A Mesorregião do Sudeste Paraense possui grande quantidade de assentamentos.[24] Altamira e são Felix do Xingu, compartilham espaços protegidos, unidades de conservação (UCs), terras indígenas, assentamentos de reforma agrária e glebas públicas federais situados nestes municípios.

Observa-se que 90,02% do território de Altamira, e 74,42% do de São Félix está tomado por áreas protegidas.[25] O município de São Felix do Xingu engloba parte da APA Triunfo do Xingu, região com forte pressão antrópica causada principalmente pelo desflorestamento decorrente da exploração da pecuária, da exploração madeireira ilegal e do avanço da atividade agrícola.

A área enfrenta um grande desafio por ter sido criada em uma área com grande concentração populacional, grande pressão antrópica, território muito degradado e muitos conflitos fundiários. Incrementando a vulnerabilidade a desmatamentos na região, ameaçando a biodiversidade.[212]

Cerca de 35,9% do desmatamento registrado em São Félix do Xingu entre 2012 e 2014 ocorreu em projetos de assentamento (PAs).[213] Este fato é verificado na Amazônia como um todo. Entre 2010 e 2014, 29,2% do desmatamento amazônico se deu nessas áreas.[214] Verifica-se que o município de Altamira abrange a gleba pública federal com o maior desmatamento entre 2012 e 2015.

4.5. Análise de Desmatamento e rodovias

A Figura 15 apresenta os resultados da classificação da área de estudo com as inter-relações: Áreas de Proteção Ambiental, dados de desmatamento (plotado na cor rosa no mapa), rodovias, do período de 2001 a 2022. É indubitavel o impacto da presença de rodovias afetando o crescimento do desflorestamento, nas últimas decadas. A classificação realizada confirma a relação das ações antropicas ocorridas com a ocorrência do desmatamento.

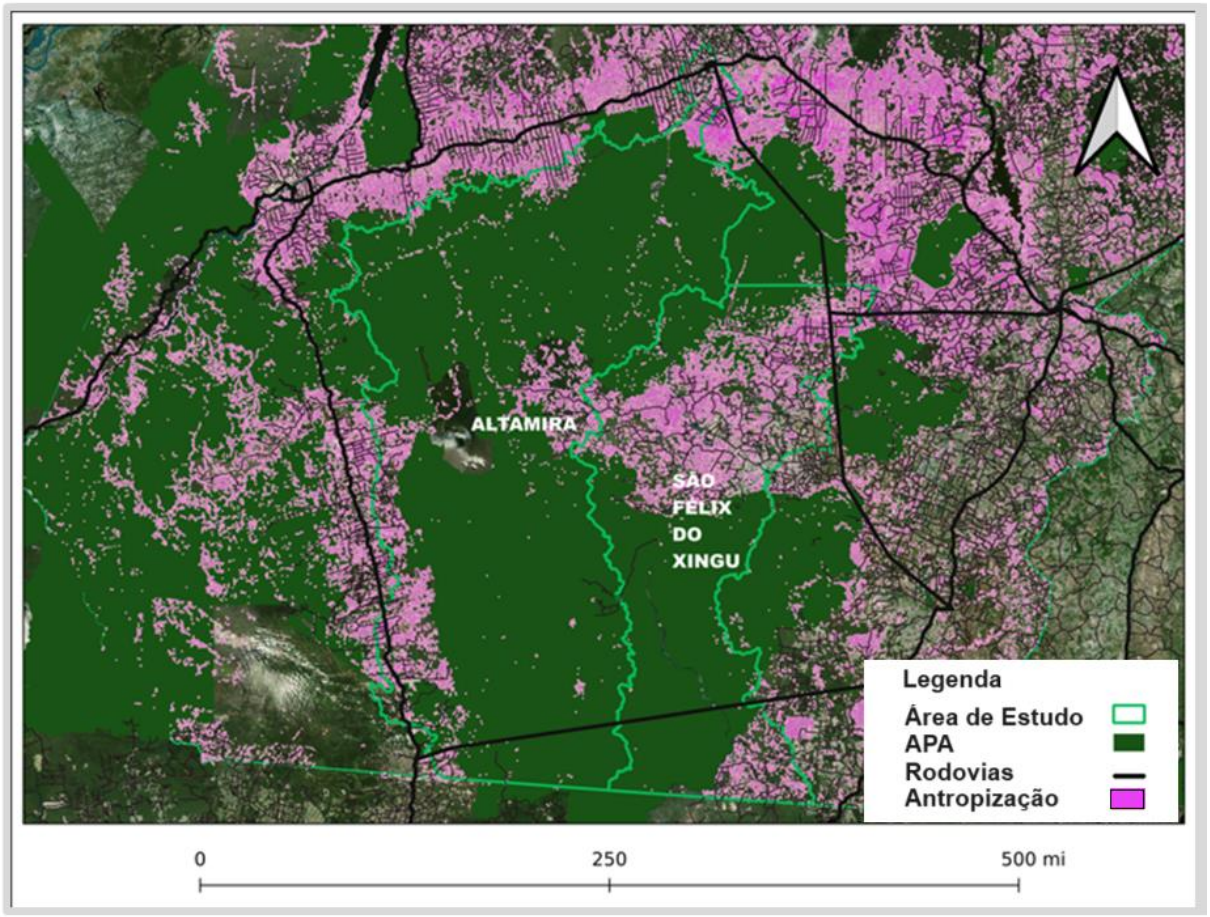

Figura 15 - Analise de Desmatamento, APA e Rodovias
Fonte: INPE

Os algoritmos utilizados geraram imagens classificadas da região de estudo. As imagens analisadas apresentaram padrões similares, considerando a analise visual dos dados processados, o comportamento geoespacial. As rodovias ocasionam a fragmentação florestal, que consequentemente gera o efeito de borda e o isolamento de populações.[74]

4.6. Análise de Desmatamento e mineração

A Figura 16 e 17 apresentam os resultados dos testes com a classificação, considerando o parâmetro Mineração: desmatamento causado por atividade de extração mineral. Predomina nesta classe atividades de garimpo artesanal[70]. A mineração ilegal é considerada como uma das principais causas do desmatamento nesta região.

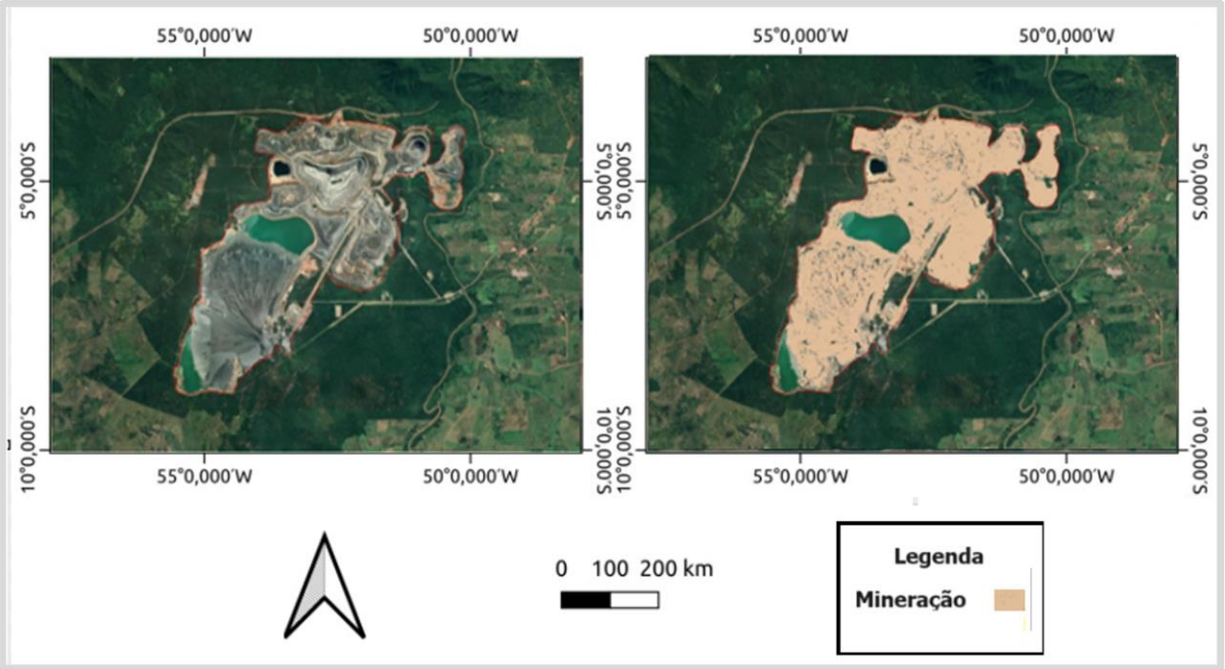

Figura 16 - Análise Desmatamento, mineração
Fonte: INPE

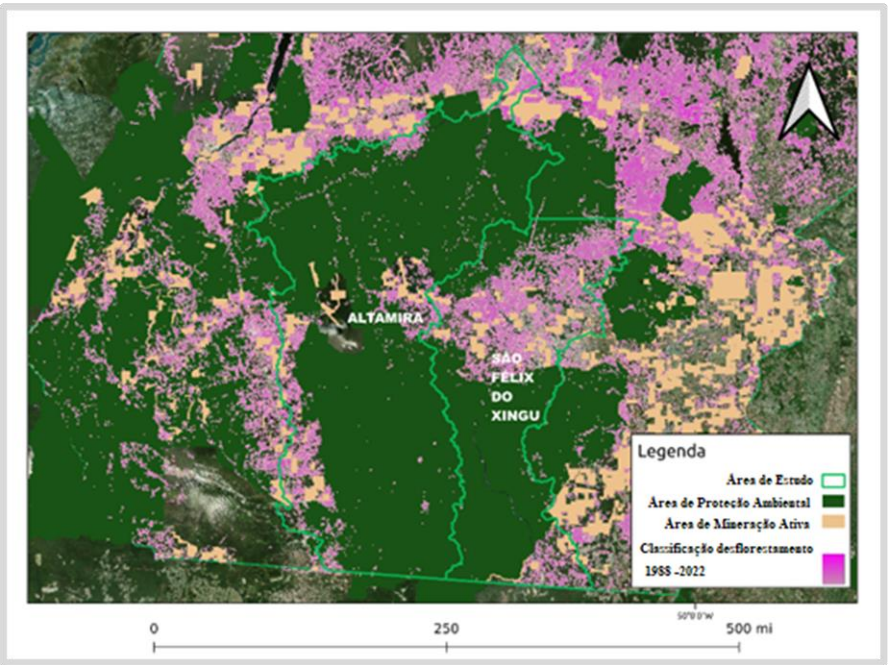

Figura 17 - Classificação, Desflorestamento, Mineração, APA
Fonte: INPE[43]

A interpretação visual comprova o constante desequilíbrio no controle do desmatamento da floresta amazônica. Este desequilíbrio é provocado devido à perda de milhares de quilômetros quadrados de vegetação a cada ano. É possível a discriminação dos alertas em classes de desmatamento e de degradação florestal. A melhor resolução espacial permitiu também identificar áreas com evidências de exploração florestal e qualificar desmatamentos por atividade de mineração, particularmente o garimpo artesanal.[70]

4.7. Análise de Desmatamento por corte raso e queimadas, considerando rodovias e mineração

O estado do Pará apresentou um dos maiores índices de focos de queimadas da Amazônia Brasileira, causando danos significativos nas áreas incendiadas e aos arredores.[215] As queimas provocam mudanças nas propriedades físico-químicas e biológicas do solo;reduzem a qualidade produtiva;[216] favorecem o empobrecimento do solo, causado pela eliminação dos microrganismos essenciais para a fertilização; contribuem com o aumento do teor de gás carbônico na atmosfera e gases tóxicos, com propriedades cancerígenas; aumenta apoluição atmosférica refletindo em aumento de doenças respiratórias.[217]

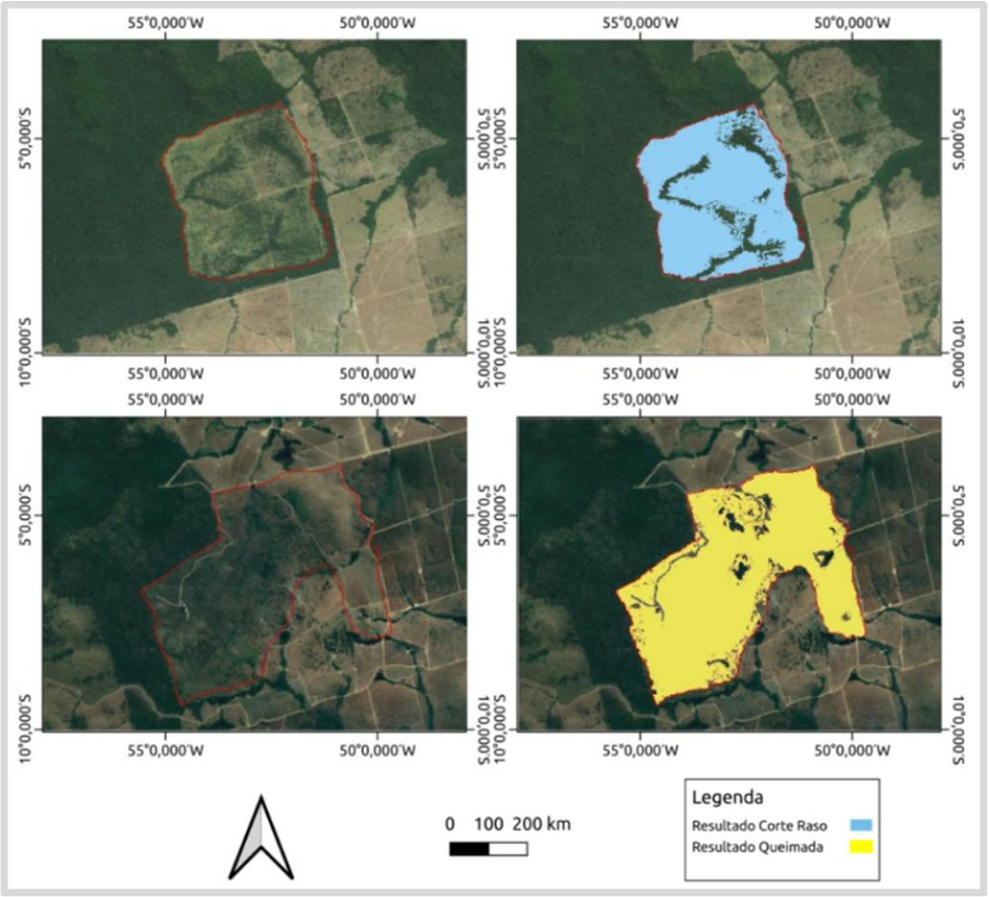

Figura 18 - Classificação Desflorestamento, Corte raso e queimada
Fonte: INPE[43]

A Figura 18 apresenta a expressão visual da classificação realizada utilizando RNC. Considerando áreas afetadas por incêndio e corte raso, observou-se disparidades com relação a quantidade classificada no raio das áreas afetadas.

Para visualizar a diferença entre as imagens classificadas, foi utilizado o algoritmo compare da ferramenta ImageMagick para gerar uma imagem com a diferença, considerando os outros algoritmos utilizados. O método RNC apresentou a melhor classificação.

A exploração madeireira ilegal e não sustentável é considerada uma causa significativa de desmatamento no estado do Pará. A extração ilegal de madeira para a produção de móveis, construção e outras finalidades tem causado a destruição de grandes áreas de floresta.

A região enfrenta desafios relacionados ao desmatamento, especialmente devido à expansão agrícola, pecuária e à construção de infraestrutura. A Expansão agrícola, a conversão de áreas florestais para o plantio de culturas agrícolas, como a soja, é uma das principais causas do desmatamento em Vitória do Xingu.

O desmatamento é muitas vezes realizado para abrir espaço para pastagens e permitir a expansão da pecuária. Infraestrutura, construção de infraestrutura, como estradas e

barragens, também pode causar desmatamento em Vitória do Xingu. A abertura de estradas facilita o acesso a áreas anteriormente isoladas, resultando na ocupação humana, expansão agrícola e exploração de recursos naturais.

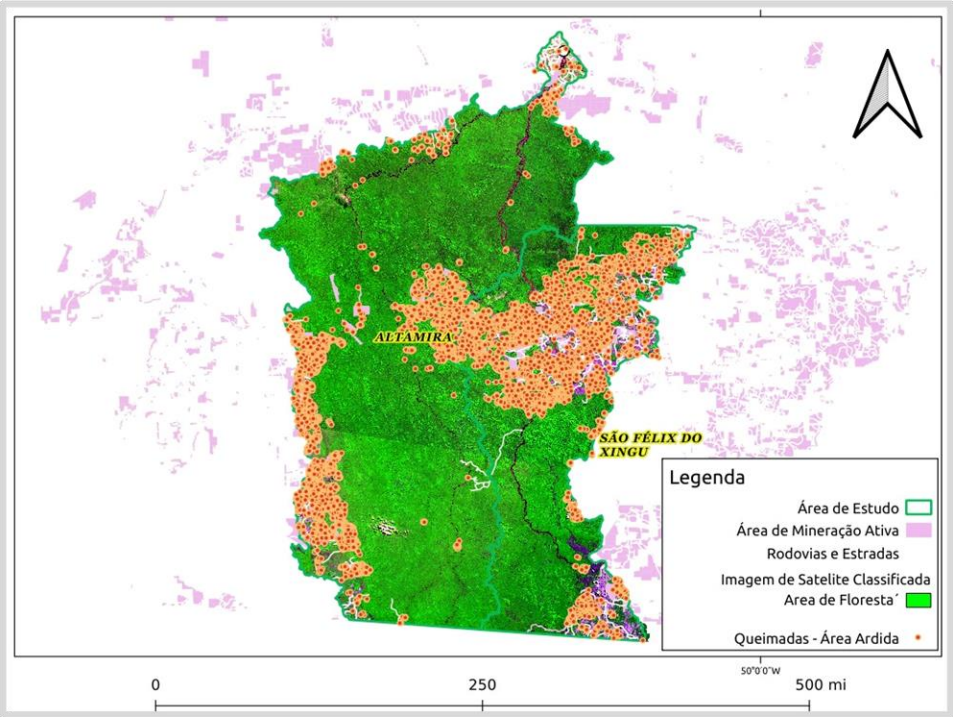

Figura 19 - Classificação desflorestamento, rodovias, mineração
Fonte: INPE[43]

A Figura 19 apresenta a expressão visual da área de estudo com a classificação dos pontos de desflorestamento relacionado com rodovias, mineração e focos de queimadas (áreas ardidas). Considerando a análises de dados quantitativos e a interpretação visual, foi constatado que focos de queimadas ocorreram de forma mais intensa próximos a estradas, rodovias e em territórios próximos a áreas de proteção ou preservação ambiental: Paquiçamba, Arara da Volta grande do Xingu, Parque nacional da serra do pardo, Triunfo do Xingu, dentre outras;

Áreas mais próximas a rodovias tendem a ter maior uso do solo destinado a atividades como agricultura, reflorestamento e urbanização. Populações que ocupam áreas mais próximas das rodovias estão expostas a processos de redução populacional, em consequência da redução e fragmentação de áreas.[212]

A construção de estradas, hidrelétricas e projetos de mineração também contribuiu para o desmatamento no estado. A abertura dessas vias de acesso facilitou a ocupação humana, a especulação de terras e a exploração de recursos naturais, resultando em perda de florestas. Impacto nas comunidades indígenas e tradicionais.

A abertura de uma rodovia pode constituir uma barreira ecológica.[122] As rodovias

ocasionam a fragmentação florestal, que consequentemente gera o efeito de borda e o isolamento de populações.[74] Consideradas agentes que facilitam ocupações antrópicas de novas áreas.[74] São estruturas complexas que tem como objetivo principal servir como via de transporte terrestre.

As rodovias representam um dos maiores males da civilização quanto aos impactos sobre o ambiente natural e causam problemas ao meio antrópico. Os benefícios das rodovias geralmente são socioeconômicos.

Os impactos negativos se fazem sobre todo o ambiente, biótico ou antrópico. O monitoramento e controle de rodovias devem considerar todos os aspectos envolvidos como: a qualidade ambiental da rodovia e a influência no desenvolvimento humano. A eliminação de uma rodovia e posterior recuperação do ambiente alterado ainda não é um fato.[122-218]

Outros impactos causados pelas rodovias seriam o pisoteamento da flora e invertebrados, afugentamento da fauna e interferência de ruídos e vibrações, redução da cobertura florestal, intervenção em áreas de preservação e unidades de conservação, risco de supressão de espécies ameaçadas de extinção, alteração do nível de risco de ocorrência de incêndios florestais, alteração na ecologia da fauna aquática e na dinâmica das águas superficiais e profundas, assim como o atropelamento da fauna.[123-219]

Durante o período de 1970-1985 ocorreu um aumento do desmatamento de 9,6 milhões de hectares, 72% explicados pela construção de estradas e 28%, por créditos subsidiados.[124-220]

No Brasil, as queimadas são ferramentas de manejo para áreas de pastagem e produção agrícola,[125-221] as queimadas conflagram incêndios florestais.[126-222] Estima-se que 90% da incidência dos incêndios florestais são de origem antrópica.[127-223] As queimadas podem favorecer a diminuição dos níveis de proteção do solo e da qualidade da água,[128-224] sobretudo, quando é realizada em períodos consecutivos. As queimadas atingem todo planeta. Este fenômeno reflete em danos ao meio ambiente, à saúde pública. As queimadas atingem áreas ocupadas por florestas e áreas ocupadas pela agropecuária.[129-225]A existência de incêndios florestais provocados por queimadas no Brasil estão relacionadas com práticas de manejo do fogo, limpeza agropastoril e desmatamentos.[226] As queimadas atingem áreas ocupadas por florestas e áreas ocupadas pela agropecuária.[225] As queimadas são responsáveis por 75% dos desmatamentos e 60% das emissões de dióxido de carbono.[12,227]Estes impactos ambientais trazem consequências nas esferas ecológica, social, econômica, ética.[227]Noventa por cento (90%) da incidência dos incêndios florestais são de origem antrópica.[223] É necessário novos e profundos estudos para compreender os fenômenos associados ao fogo. Referem-se ao conhecimento e comportamento de diferentes sujeitos e grupos sociais.[205]

O período mais longo de frequência de chuvas abaixo da média histórica foi entre 2010 e 2013, mesmo período em que o INPE registrou a maior quantidade de focos de calor no Pará, concomitantemente à ocorrência de forte intensidade para o fenômeno El Niño.[225] A presença desse fenômeno na região Norte ocasiona redução drástica de chuvas em todos os domínios, em especial no Norte, Leste e Sudeste da Amazônia.

A identificação das causas do desmatamento são complexas, pode ser afetada por inúmeros fatores: a baixa qualidade dos dados (capturados em campo e/ou analisados); a abordagem metodológica (normativa, positiva, estatística, estrutural); o nível de análise (local, nacional, entre países); a distinção entre desmatamento e expansão da fronteira agrícola; a identificação de áreas próprias para extração de madeira; a ocorrência de incêndios; o comércio de madeiras; a expansão de atividade agropecuária; o aumento da densidade populacional; incentivos fiscais.[43] As causas do desmatamento nas florestas tropicais, são difíceis de serem identificadas, estão relacionadas a uma combinação de fatores que favorecem a de gradação ambiental, como: a interação entre a expansão agrícola, o comércio de madeiras, crescimento populacional, a construção de estradas, governança pública, e que podem interagir de maneira diferente, dependendo da dinâmica temporal e espacial de cada região.[228]

4.8. Análise de desmatamento e agropecuária industrial

A Figura 20 apresenta uma área de agropecuaria industrial, a classificação de cada um dos pixels processado, o resultado da segmentação semântica. A Figura corresponde a amostra de uma imagem processada de agropecuaria. A classificação realizada com os metodos KNN,RF e RNC não diferenciou Corte raso de Pecuaria precisamente. Por isso, este parâmetro (agropecuária) não consta nos objetivos/metodologia.

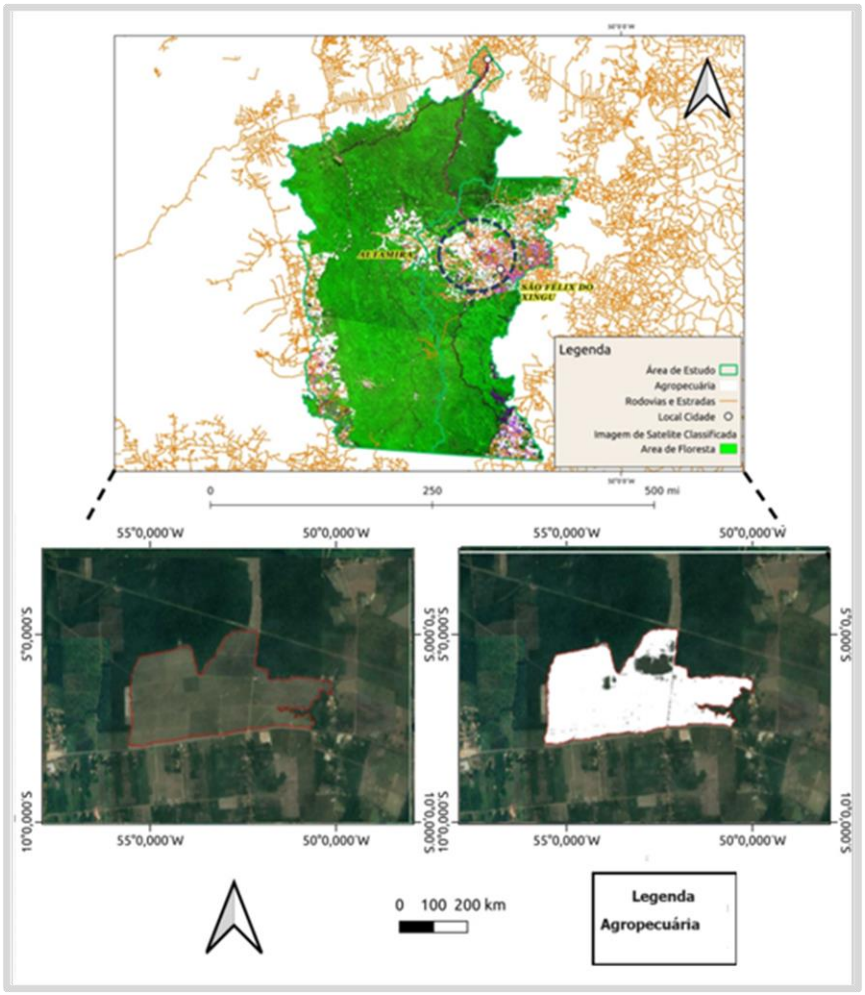

Figura 20 - Classificação Agropecuária industrial
Fonte: INPE[43]

No município de São Félix do Xingu, a pecuária é uma das principais atividades diretamente relacionadas ao desmatamento na região. O desmatamento incrementa a fragmentação, tendo como consequência a perda da biodiversidade e o isolamento. Ocorrendo o aumento da proporção de áreas de borda. [229]

A pecuária é a atividade responsável pela maior parte do desmatamento. A pecuária de média e grande escala é altamente rentável do ponto de vista privado e apresenta taxas de retornos superiores às da pecuária tradicional.[69] A pecuária está ligada às práticas de desenvolvimento da região amazônica.[69] Os benefícios dessa atividade são menores do que

as perdas ambientais. A ocupação para a pecuária responde em cerca de 75% dos desmatamentos. No período de 1970 a 1995, houve um crescimento significativo da renda regional. Contudo, os indicadores sociais e econômicos regionais mostraram que a maior parcela da rendase originou nas áreas urbanas e não nos setores rurais.

A criação de gado é uma atividade que tem contribuído para o desmatamento na região. O desmatamento é muitas vezes realizado para abrir espaço para pastagens e permitir a expansão da pecuária. No município de SFX e Altamira a pecuária, exploração madeireira, atividade agrícola, agropecuaria é uma das principais atividades econômicas.

O desmatamento é primariamente causado pela necessidade de se transformar florestas em terras para atividades agropecuárias.[230] A busca pelo crescimento econômico como uma das principais causas de cunho macroeconômico da degradação ambiental. A construção de estradas;[121]A pecuária em larga escala;[231]A expansão da fronteira agrícola;[69]A densidade populacional,[232] estão entre as causas do desmatamento na região.

De 1990 a 2006, o rebanho bovino cresceu a uma taxa média de 6,74% ao ano na Amazônia Brasileira, enquanto nas outras regiões do Brasil o crescimento médio do rebanho foi de 0,57% ao ano.[233] Com essas taxas, segundo os dados da Pesquisa Pecuária Municipal do IBGE,o rebanho cresceu de 26 milhões de cabeças em 1990 para 73,7 milhões em 2006, o que representa um aumento de mais de 180% em 16 anos.[233] O crescimento acompanhou o aumento da demanda interna e externa de carne bovina.

A dinâmica ocupacional da Amazônia pautada sob a lógica agropecuária, minero-metalúrgica e fundiária resultou em um grande processo de antropização, que tem graves consequências ambientais e sociais, no qual o desmatamento é uma das maiores problemáticas que podem ser citadas e a partir desse fenômeno.[234]

Entre as principais consequências apresentadas pela destruição e desaparecimento dessa vegetação estão: ausência da cobertura vegetal; alteração das condições e características locais; desequilíbrio ecológico em grandes dimensões; escoamento superficial de resíduos lpara o leito dos rios, com acúmulo de sedimentos e o rebaixamento do nível do lençol freático; perda da fertilidade do solo; extinção de espécies de animais terrestres e aquáticos.[235]

A criação de gado requer a utilização de grandes áreas, o que potencializa o processo de conversão de floresta em pastagem. A baixa longevidade da produtividade, associada com a baixa fertilidade dos solos da Amazônia e práticas inadequadas de manejo, estimulam os produtores a abandonar suas áreas originais em busca de outras áreas para a implantação de novas pastagens, em geral, avançando sobre áreas de florestas primárias.[236]

O desmatamento é primariamente causado pela necessidade de se transformar florestas em terras para atividades agropecuárias.[250] A busca pelo crescimento econômico

como umadas principais causas de cunho macroeconômico da degradação ambiental. A construção de estradas;[121]A pecuária em larga escala;[251]A expansão da fronteira agrícola;[237]A densidade populacional,[238]estão entre as causas do desmatamento na região Amazônica Legal.[66]As correlações entre o desmatamento e o avanço do setor agropecuário tornaram-se mais altas, especialmente a partir de 1994.[66]

Em cenários de desmatamento parcial foi observado aumento na precipitação local. Ao simular um desmatamento maior, notou-se um clima mais seco, com redução na precipitação local.[239] Foi observado um padrão dipolar da precipitação em resposta ao desmatamento amazônico, indicando decréscimo da precipitação no setor oeste e um acréscimo no setor lesteda Bacia Amazônica.[240] Foi observado um padrão de precipitação dipolar oposto, onde o Oeste (leste) amazônico tornava-se mais úmido (seco).[241] Entretanto, foi observado alterações no clima de regiões distantes da área desmatada na Amazônia, como variações na precipitaçãono nordeste do Atlântico, estendendo-se para o oeste da Europa, durante o inverno.[242]

Foi observado que o desmatamento amazônico reduziu significativamente a precipitação na América do Norte, entretanto, em regiões mais distantes dos trópicos, os sinais desta teleconexão se enfraqueciam.[243] Foi observado um padrão de precipitação dipolar oposto,onde o oeste (leste) amazônico tornava-se mais úmido (seco).[241]

Em áreas de pastagem há uma menor absorção de radiação solar à superfície e uma redução da evapotranspiração e da umidade do ar.[244] A ciclagem da água realizada na Amazôniaé exportada para outras regiões do Brasil e para países adjacentes. Parte desta água consegue ultrapassar os Andes, porém, sua maior parcela é desviada para o Sul quando encontra a barreira andina.[245]

As alterações climáticas associadas ao aumento do desmatamento na floresta amazônica podem estimular mudanças na sua vegetação. A floresta depende de um regime de chuva, considerando o ano, e qualquer impacto que ocorra, como a diminuição de precipitação, desequilibra a resiliência da floresta.[246]

Nos próximos 100 anos, as mudanças climáticas antropogênicas serão um dos principais motivadores de perda de biodiversidade no planeta. As temperaturas anuais aumentaram aproximadamente de 1°C a 4°C em 2100.[247] Países em desenvolvimento, como o Brasil, sofreram possíveis impactos nos ecossistemas com as alterações climáticas e ambientais.[248] Os processos de desmatamento e seus impactos ambientais se dão de forma gradativa. Estes processos não devem ser “considerados como representativos apenas do ano em que o desmate final foi constatado”.[233]

5. Conclusão

A Inteligencia Artificial (IA) aplicada ao combate e redução do desmatamento na Amazônia é um desafio complexo, pois, requer ações conjuntas de todos os agentes envolvidos nesse fenômeno, como governos, organizações não governamentais, comunidades locais, sociedade civil, sobretudo, a colaboração de especialistas e cientistas. O combate ao desmatamento ilegal, o fortalecimento da fiscalização, a aplicação da legislação ambiental, o incentivo a práticas agrícolas e pecuárias sustentáveis, a promoção da conservação, o estabelecimento de políticas de conservação florestal, a implementação de sistemas de gestão florestal responsáveis, a conscientização sobre a importância das florestas para o meio ambiente, a cooperação internacional, a conscientização pública, são medidas fundamentais para proteger as florestas brasileiras e enfrentar esse problema, objetivando garantir a preservação dessa região. A IA é uma solução que pode complementar e fortalecer essas estratégias, auxiliando na tomada de decisões e na implementação de medidas eficazes de conservação florestal e reflorestamento.

As consequências do desmatamento na área de estudo são similares às observadas para a região amazônica em geral: o desmatamento contribuiu com à destruição de habitats naturais, causando a perda de espécies vegetais e animais. A Amazônia caracteriza um importante regulador do clima global devido a sua vasta dimensão elocalização próxima a linha do Equador. O desmatamento também afetou, nas últimas decadas, diretamente as comunidades locais, que dependem da floresta para sua subsistência e preservação cultural. A destruição dos recursos naturais e a perda do acesso a esses recursos podem ter consequências negativas para as comunidades locais. A retirada das florestas afetam a conservação do solo, influenciaram na umidade e erosão; na proteção e filtragem da água. As florestas desempenham um papel fundamental na regulação do clima global, e o desmatamento libera grandes quantidades de carbono armazenado nas árvores. Por isso, Investimentos em energias renováveis, como a energia solar, eólica e de biomassa, podem impulsionar o desenvolvimento econômico da região, reduzindo a dependência de fontes não renováveis e diminuindo as emissões de gases de efeito estufa. A regularização fundiária e o combate ao desmatamento ilegal são fundamentais para garantir a segurança jurídica das áreas e promover o uso sustentável dos recursos naturais.

A Amazônia passará por mudanças irreversíveis, com tendência à savanização, se continuar com indices altos de desmatamento. As consequências de um mundo sem a Amazônia são “catastróficas” para o Brasil e para o planeta. Iimpactos sócio ambientais observados nesta região torna evidente a necessidade de manutenção de baixas taxas de desflorestamento. Esta manutenção poderá amenizar à ameaça de continuidade da tendência

de aumentos significativos da taxa de desmatamento anual na Amazônia Brasileira.

A utilização de Inteligencia Artificial, considerando o cenário relatado nos paragrafos anteriores, devem ser consideradas no desenvolvimento e na implementação de soluções, que auxiliem em processos de tomada de decisão. O algoritmos de IA utilizados foram fundamentais e precisos para a analise e identificação de processos que contribuiram diretamente com a ocorrência do desflorestamento, nesta região, como a mineração, as queimadas, o surgimento de rodovias, ou seja, processos de antropização ocorridas nas últimas décadas. O uso da IA também confirmou que as áreas de proteção ambiental são barreiras naturais que amenizam o avanço do desmatamento, nesta região.

A realização da classificação de imagens de satélite na região amazônica ainda apresenta desafios específicos, devido às características peculiares da cobertura terrestre e à complexidade da vegetação tropical. A classificação de imagens de satélite apresenta muitos avanços científicos, aprimoramento de técnicas, métodos, ferramentas, procedimentos. A identificação de um pixel no mapa de risco de desmatamento, com a probabilidade de desmatamento é utilizada para auxiliar processos de tomada de decisão, controlar e prevenir futuros desmatamentos na região. Por isso os resultados deste trabalho contribuíram com a identificação precisa de regiões antropizadas, na Amazônia, processo desafiador devido à alta cobertura florestal e à complexidade da vegetação. A presença de nuvens também representou um desafio adicional. Para amenizar esse problema foi utilizado técnicas de acordo com as características específicas da região amazônica e o contexto de aplicação desejado.

O modelo de Rede Neural Convolucional (RNC) apresentou os melhores resultados para a classificação de imagens de satélite, considerando os outros modelos utilizados (KNN e RF). Os resultados da classificação dos três algoritmos foram similares, considerando a interpretação visual, ou seja, cor, tonalidade, textura, forma e contexto, foi difícil diferencia-los, visualmente, devido as similaridades observadas, devido a área ser muito extensa. O modelo de RNC apresentou complexidade maior no campo de imagens espectrais de satélite. Diferenças de pixels, resoluções e composições de bandas de satélite (modo de captura e distância orbital); alguns parâmetros que influenciam diretamente no comportamento e performance da rede Convolucional: número de filtros (kernel), tamanho dos filtros, stride (deslocamento do filtro ao longo da imagem de entrada), pooling (redução da dimensão espacial dos mapas ao longo das camadas da rede), camadas densas, escolhas de função de ativação. Por isso, durante a predição e classificação de imagens da região a RNC apresentou capacidade de atingir alto desempenho em tarefas visuais complexas; capacidade de aprender automaticamente um grande número de filtros; permitiu a solução de problemas

de diferentes segmentos; reconhecimento de imagens com altíssimas taxas de acerto. Esse fato ocorreu, pois, as redes neurais convolucionais foram projetadas especificamente para processamento de imagens e têm sido fundamentais para os avanços na visão computacional e processamento de dados em grade.

A estratégia de classificação de imagens de satélites, utilizando o RNC, KNN e RF obteve bons resultados. O principal desafio foi diferenciar os pixels das classes avaliadas, a interpretação visual das classes, devido à proximidade entre as intensidades dos canais RGB dos pixels na imagem. A segmentação das imagens foi realizada utilizando algumas estratégias, com os algoritmos de correções. Após essas correções o RNC manteve-se apresentando os melhores resultados. A aplicação dos filtros com máscara de tamanho 3x3 se mostrou promissora para a classificação dos pixels, ocorreu a eliminação de alguns ruídos na segmentação dessas regiões, destacada pela melhoria de acurácia nas segmentações realizadas pelos algoritmos RNC. Conforme o aumento do tamanho da máscara a classificação dos pixels das classes avaliadas, resultou na melhoria de acurácia nas segmentações realizadas pelos algoritmos RNC. Este processo favoreceu o mapeamento de grandes regiões, como as áreas florestais, onde os pixels representam uma área de poucos metros, alguns elementos, como uma árvore, devido a cor, podem prejudicar a segmentação de uma região.

Considerando os resultados de cada algoritmo, durante o treinamento e testes, para cada uma das bases de dados, foi observado a necessidade de utilização de um conjunto maior de imagens de satélite assim como o tratamento das imagens e o tratamento dos dados utilizados. Por isso, a temporalidade da análise, concentrou-se no período estudado, 2001 a 2022. A temporalidade justifica-se, também, a partir da análise de tendencias, que refletem em avanços expressivos do desmatamento, em vários períodos, como em 2019.

As imagens processadas apresentaram semelhanças (comportamento da disposição geoespacial dos dados) com relação as áreas afetadas por incêndio e corte raso. Após o processamento, os algoritmos geraram imagens classificadas da região de estudo. A identificação visual da classe Mineração foi mínima e imperceptível, pois somando ao acerto presente na matriz de confusão, considerando os 3 modelos, temos 74 máscaras 3x3 ditas da classe Mineração. De fato, os municípios de estudo não possuem grandes extensões de atividade mineradora, considerando a analise visual dos pixels, sobretudo devido à grande extensão da área.

Os dados resultantes da classificação utilizando RNC mostram uma diferença dos dados de desflorestamento, no período de 2001 a 2022, considerando as taxas do PRODES. A taxa

de desflorestamento computada, no período de 2001 a 2022, corresponde, aproximadamente, 65.830 Km2. No entanto, os resultados da classificação utilizando a RNC computou, aproximadamente, 68.035 Km2. A diferença, entre esses dados, pode ser explicada devido ao limite histórico dos dados monitorados pelo PRODES. Entretanto, durante os processos de captura de imagens de satélite é possível observar a área estudada de forma geoespacial e temporal. Possivelmente a diferença corresponde a antropização (alterações ambientais, sociais ocorridas no espaço geográfico) do período anterior a 1988, apresentando uma nova perspectiva dos índices de desmatamento. Esta diferença ocorreu, também, devido a natureza do sistemas que o PRODES utiliza, considerando, questões tecnológicas, como os tipos de sensores óticos utilizados, características físicas da radiação eletromagnética na faixa do espectro visível, por exemplo, o imageamento ótico é bloqueado pela presença de nuvens. Assim como, peculiaridades da região, presença constante de nuvens.

O desmatamento, na área estudada, foi menor nas áreas indígenas. Essas áreas estão resistindo diante deste problema, escudo natural que contribui com a preservação desta floresta. Por isso, é estratégico envolver e valorizar as comunidades locais e indígenas durante o processo de tomada de decisões relacionadas ao desenvolvimento econômico da região, juntamente com o apoio do governo e de organizações ambientais, é fundamental para garantir a preservação das florestas e a sociobiodiversidade da região.

O combate e controle do desflorestamento em São Félix do Xingu e Altamira se torna um grande desafio, sobretudo devido as peculiaridades da região: Histórico de desflorestamento, APA, extensão territorial, atividades econômicas. Modelos de risco de desmatamento podem ser úteis para indicar quais são as áreas críticas. A área estuda (estado do Pará) tem sido historicamente um dos estados com as maiores taxas de desmatamento no país. No entanto, políticas públicas recentes, em desenvolvimento, auxiliam na redução de índices históricos, nesta região.

O governo brasileiro tem implementado medidas para enfrentar o desmatamento, no entanto, o desafio de controlar o desmatamento e promover a conservação continua sendo uma tarefa complexa, exigindo esforços conjuntos. Sendo assim, para garantir a proteção, a preservação ambiental, da maior floresta tropical do mundo é urgente a implementação de um modelo de desenvolvimento econômico, sobretudo, usando Inteligência Artificial, que auxilie em processos de proteção ambiental e reflorestamento, considerando, sobretudo, a socio biodiversidade, a Bioeconomia para garantir um futuro sustentável do planeta.

6.Referências

[1] BRASIL - MINISTÉRIO DA CIÊNCIA E TECNOLOGIA. Estimativas anuais de emissões de gases de efeito estufa no Brasil. Brasília-DF. 2022.

[2] ANGELSEN, A. Agricultural expansion and deforestation: modelling the impact of population, market forces and property rights. Journal of Development Economics, v. 58, n. 1, p. 185-218. 1999.

[3] FONSECA, F. LINDOSO, D. P. BURSZTYN, M. Falta de controle do desmatamento na Amazônia brasileira: do fortalecimento ao desmantelamento da autoridade governamental (1999-2020). Sustainability in Debate, 13(2):12–31, 2022. Number: 2.2022.

[4] FERREIRA, A. B. Modelagem da biomassa e dinâmica do carbono em áreas de concessão florestal no sudeste da Amazônia brasileira. Tese (Doutorado - Mestrado em Ciências Florestais). 76 p.Universidade de Brasília Brasília, 2019.

[5] VERÍSSIMO, A.; LIMA, E.; LENTINI, M. Pólos madeireiros do estado do Pará.IMAZON, Belém, p. 72, 2002.

[6] RIBEIRO, S. C. et al. Quantificação de biomassa e estimativa de estoque de carbono em uma floresta madura no município de Viçosa, Minas Gerais. Revista Árvore, [s. l.], v. 33, n. 5, p. 917–926, 2009.

[7] WANG, X. Q. G. LEWIS, B. J. YU, D. ZHOU, L.Q. L. WANG, Y. LI, G. DAI, L.SU, D. Research paper Spatiotemporal Variations in Biomass Carbon Storage for Three Forest Management Regimes in Northeast China. 2011.

[8] HOMMA, A. K. O. Expansão agropecuária e desmatamento na Amazônia: Quais os caminhos. In: COELHO, A. B., TEIXEIRA, E. C. e BRAGA, M. J. (Eds.). Recursos Naturais e Crescimento Econômico. 1. ed. Viçosa, MG. 2008.

[9] SUDAM - SUPERINTENDÊNCIA DO DESENVOLVIMENTO DA AMAZÔNIA. Legislação sobre a criação da Amazônia Brasileira. 2020.

[10] BOLTZ, F. HOLMES, T. P. CARTER, D. R. Economic and environmental impacts of conventional and reduced-impact logging in Tropical South America: a comparative review. Forest policy and economics, v. 5(1), p. 69–81, 2003.

[11] ASNER, G. P. KELLER, M. S I LVA, J. N. M. Spatial and temporal dynamics of forest canopy gaps following selective logging in the eastern Amazon. Global Change Biology. 2004.

[12] HENDRINSON, J. Damage – Controlled logging in managed tropical rain forests in Suriname. Wageningen Agricultural University, 1989.

[13] HOMMA, A. K. O. Expansão agropecuária e desmatamento na Amazônia: Quais os caminhos. In: COELHO, A. B., TEIXEIRA, E. C. e BRAGA, M. J. (Eds.). Recursos Naturais e Crescimento Econômico. 1. ed. Viçosa, MG. 2008.

[14] SUDAM - SUPERINTENDÊNCIA DO DESENVOLVIMENTO DA AMAZÔNIA. Legislação sobre a criação da Amazônia Brasileira. 2022.

[15] ANDERSEN, L. E. et al. The dynamics of deforestation and economic growth in the Brazilian Amazon. Cambridge: Cambridge University Press, 2002. p. 259. 2002.

[16] IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Indicadores de Desenvolvimento Sustentável: Brasil 2010. Rio de Janeiro, RJ: [s.n.]. 2010.

[17] IBGE - INSTITUTO BRASILEIRO DE GEOGRAFIA E ESTATÍSTICA. Território e Ambiente. 2020.

[18] PROGRAMA MUNICÍPIOS VERDES (PMV). Diagnóstico da gestão ambiental municipal nos municípios vinculados à base local Altamira. 2017a.

[19] LE TOURNEAU, F. M.; M. BURSZTYN, M. Assentamentos rurais na Amazônia: Contradições entre a política agrária e a política ambiental. Ambiente & Sociedade, Campinas v. XIII, n. 1p. 111- 130. jan.-jun. 2010.

[20] INSTITUTO SOCIOAMBIENTAL (ISA). Terras indígenas no Brasil. 2017a.

[21] COSTA, A.L.S., REIS, L.R., 2017. A contribuição da APA Triunfu do Xingu para o ordenamento fundiário na região da Terra do Meio, Estado do Pará. Revista de Ciências Agrárias. Amazon Journal Of Agricutural And Environmental Sciences 60, 96-102.2017.

[22] ICMBIO. “Análise do Desmatamento nas Unidades de Conservação Federais Localizadas na Amazônia”. Ministério do Planejamento, 2010.

[23] BRASIL. Decreto nº 2.483, “Cria a Floresta Nacional de Altamira, no Estado do pará, e dá outras providências”, de 2 de Fevereiro de 1998.

[24] BRASIL. Decreto n º 2.788, “Altera disposiivos do Decreto nº 1.282, de 19 de outubro de 1994, e dá outras providências”, de 28 de Setembro de 1998.

[25] BEZERRA, N. R. C. A Amazônia e os novos paradigmas de desenvolvimento rural: uma breve reflexão teórica. Revista Brasileira de Agroecologia, v. 6, n. 2, 2011.

[26] HEMANI PARIKH, Samir Patel, e Vibha Patel. Classification of sar and polsar images using deep learning: a review. INTERNATIONAL JOURNAL OF IMAGE AND DATA FUSION, 11(1):1–32, JAN .2. 2020.

[27] XIAO, X. Z. Sina Montazeri, Mohsin Ali, Yuansheng Hua, Yuanyuan Wang, Lichao Mou, Yilei Shi, Feng Xu, e Richard Bamler. Deep learning meets SAR: Concepts, models, pitfalls, and perspectives. IEEE Geoscience and Remote Sensing Magazine, 9(4):143–172, 2021. Conference Name: IEEE Geoscience and Remote Sensing Magazine.2021.

[28] CARVALHO, M. S.; COSTA, H. M. Procópio da Implementação e análise de métodos de classificação de imagens SAR para detecção automatizada de desmatamentos, com base em aprendizagem de máquina. Universidade de Brasília, Brasília, 2023.

[29] INPE. Monitoramento do desmatamento da floresta amazônica brasileira por satélite. http://www.obt.inpe.br/prodes/, 2022.

[30] BARROSO, L. R. PERRONE, P. C. M. COMO SALVAR A AMAZÔNIA: POR QUE A FLORESTA DE PÉ VALE MAIS DO QUE DERRUBADA. Revista de Direito da Cidade, Rio de Janeiro, vol. 12, vol. 12, nº 2. 2020. p. 9.2020.

[31] ARRUDA, E. A flexibilização da legislação ambiental e o desmatamento da Amazônia: o agravamento do desmate e suas motivações com base em decisões judiciais de 2019 a 2021. 2022.

[32] INPE - Instituto Nacional de Pesquisas Espaciais- Como se monitora o desmatamento da Amazônia? http://www.inpe.br/faq/index.php?pai=6.2023.

[33] MOHAN, M. et al. UAV-supported forest regeneration: current trends, challenges and implications. Rem. Sens. 2021.

[34] ORTEGA. A. Mabel, Q. F. Raul, N. H. Evaluation of deep learning techniques for deforestation detection in the Brazilian Amazon and cerrado biomes from remote sensing imagery. Rem. Sens. 6 (2020), 910. 2020.

[35] PANEQUE, G. Small drones for community-based forest monitoring: an assessment of their feasibility and potential in tropical areas. Forests 6. 2014.

[36] INPE. Portal TerraBrasilis (Instituto Nacional de Pesquisas Espaciais (INPE), 2020.

[37] WRIGHT, T. M. Harnessing multiple technologies to combat deforestation–a case study in the alto mayo protected forest in San Martin. Peru. PARKS 24 (2018), 79. 2018.

[38] MACHIDA, F. A. E. Modelagem e Análise da Prevenção do Desmatamento por Sistemas de Monitoramento Baseados em Veículos Aéreos Não Tripulados. Modelagem Ambiental e Software. Editor: Elsevier. Data: Dezembro de 2022.

[39] SARLET, I. W. Curso de Direito Ambiental. [São Paulo]: Grupo GEN, 2021. p. 64.2021.

[40] COPERTINO, M. et al. Desmatamento, fogo e clima estão intimamente conectados na Amazônia. Ciência e Cultura, volume 71, nº 4, São Paulo, Out./Dez. 2019. Disponível em: http://cienciaecultura.bvs.br/scielo.php?script=sci_arttext&pid=S0009-67252019000400002.2019.

[41] BARRETO, P. Políticas para desenvolver a pecuária na Amazônia sem desmatamento. Amazônia 2030, agosto 2021. Disponível em: https://amazonia2030.org.br/wp-content/uploads/2021/09/pecuaria-extrativa_final_Paulo-Barreto-1.pdf.2021.

[42] BRITO, B.et al. Dez fatos essenciais sobre regularização fundiária na Amazônia (2021): 104. Belém: Imazon.2021.

[43] STABILE, M.C.C. et al. “Solving Brazil’s Land Use Puzzle: Increasing Production and Slowing Amazon Deforestation”. Land Use Policy 91 (2019): 104362. https://doi.org/10.1016/j.landusepol.2019.104362.2019.

[44] FEARNSIDE, P.M., L. Ferrante, A.M, Yanai, and M.A. Isaac Junior. 2020a. Trans-Purus: Brazil’s last intact Amazon Forest at immediate risk (commentary). Mongabay, 24 November 2020. https://bityl.co/4o8J. 2020.

[45] GARRETT, R. et al. Apoiando socio bioeconomias de saudáveis florestas em pé e rios fluindo na amazônia.2020.

[46] BEZERRA, N. R. C. A Amazônia e os novos paradigmas de desenvolvimento rural: uma breve reflexão teórica. Revista Brasileira de Agroecologia, v. 6, n. 2, 2011.

[47] MONTEIRO, M. A; COELHO, M. C. N. As políticas federais e reconfigurações espaciais na Amazônia. Novos Cadernos NAEA, Belém, v. 7, n. 1, p. 91-122, jun. 2004.

[48] BINSWANGER, H.P. Brazilian Policies that Encourage Deforestation in the Amazon. Working Paper n.16, World Bank, 24 p., 1989.

[49] GODOY, A. M. G. Desequilibrios ambientais na agricultura brasileira: avanços ou continuidade no Plano Plurianual do governo Lula?. In: Encontro da ANPPAS, Indaiatuba- SP. Anais do II Encontro da ANPPAS, v. 1. p. 1-20, 2004.

[50] LOPEZ, R. Environmental Degradation and Economic Openness in LDCs: The Poverty Linkage. American Journal of Agricultural Economics, v. 74, n. 5, p. 1138-50, 1992. Disponível em: <http://www.jstor.org/pss/1242771>.1992.

[51] LOENING, L. J. e MARKUSSEN, M. Pobreza, Deforestación y Pérdida de la Biodiversidad en Guatemala. Discussion Papers. ISSN 1431-181X, 2003.

[52] TUPIASSU, L. FADEL, L. P. S. L; GROS-DÉSORMEAUX , J. R. ICMS Ecológico e desmatamento nos municípios prioritários do estado do Pará. Revista Direito GV. vol.15 no.3 São Paulo 2019 Epub Oct 14, On line version ISSN 2317-6172. https://doi.org/10.1590/2317-6172201928. 2019.

[53] PRATES, R. C. O desmatamento desigual da Amazônia brasileira: sua evolução, suas causas e consequências sobre o bem-estar. Tese (Doutorado em Ciências). 2023.

[54] ALVES, D. et al. The changing rates and patterns of deforestation and land use in Brazilian Amazonia. In: KELLER, M. et al. (Ed.). Amazonia and global change. Washington, DC: AGU, 2009. p. 11-23. (Geophysics Monograph Series, 186);2009.

[55] MARGULIS, S. Causas do Desmatamento da Amazônia Brasileira. Banco Mundial – Brasília: julho, 2003.

[56] VALERIANO, D. M.; NARVAES, I. S.; MAIA, J. S.; GOMES, A. R.; DINIZ, C. G.; SOUZA, A. A. A. Metodologia do sistema DETER – B (sistema de detecção do desmatamento e alterações na cobertura florestal em tempo quase real). Mapeamento de alertas com imagens dos sensores AWiFS-Resourcesat-2 e WFI-Cbers-4. São José dos Campos: INPE, 2016.

[57] ZIEGLER, M. F. Grandes projetos de infraestrutura na Amazônia deixaram legado socioambiental danoso, dizem cientistas. FAPESP. 28 de setembro de 2021.

[58] ZAIDAN, R.T. Geoprocessamento Conceitos e Definições. Revista de Geografia. PPGEO -UFJF. Juiz de Fora, v.7, n.2, (Jul-Dez) p.195-201, 2017.

[59] GUIMARÃES, F. Rede neural Convolucional (RNC). O que é e como funciona. Brasil: Mundo Projetado, 14 set. 2021. Disponível em: https://mundoprojetado.com.br/rede-neural-convolucional/.2021.

[60] CAVALCANTE, E. S. Análise preditiva com redes neurais convolucionais para o geoprocessamento de imagens. 2023.

[61] SANTOS, A. R. D. ArcGis 9.1 Total . Vitória-ES: Fundagres, 2007. 226 p.2007.

[62] DE LANA, L. C. et al. Desenvolvimento de um sistema de informações geográficas para aplicações ambientais e de saneamento: SIGAS-UERJ. Revista Brasileira de Geomática, v. 10, n. 4, p. 260-278, 2023.

[63] LILLESAND, T. Remote Sensing and Image Interpretation. Wiley, 2015.

[64] PETER, B. R. Principles of geographical information systems. Oxford University Press, USA, 2015.

[65] LEE, C. The use of geographical information systems in climatology and meteorology. Progress in Physical Geography: Earth and Environment, 27(3):313–330, 2003.

[66] SCOTT, B. Professional practice and innovation: Geographical information systems: An effective planning and decision-making platform for community health coalitions in Australia. Health Information Management Journal, 39(3):28–33, 2010. PMID: 28683684.2010.

[67] BATEMAN, A.P. Applying Geographical Information Systems (GIS) to Environmental and Resource Economics. Environmental and Resource Economics, 22(1):219–269, June 2002.

[68] PHILIPPA J. Image processing and GIS for remote sensing - techniques and applications. John Wiley amp; Sons Incorporated, 2016.

[69] KWANG-SOO, K. On integrated scheme for vector/raster-based GIS's utilization. In IGARSS'97. 1997 IEEE International Geoscience and Remote Sensing Symposium Proceedings. Remote Sensing - A Scientific Vision for Sustainable Development, volume 1, pages 200–203 vol.1, 1997.

[70] XIULIN, LOU. Raster to vector conversion of classified remote sensing image. In Proceedings. 2005 IEEE International Geoscience and Remote Sensing Symposium, 2005. IGARSS '05., volume 5, pages 3656–3658, 2005.

[71] MENESES, P. R. INTRODUÇÃO AO PROCESSAMENTO DE IMAGENS DE SENSORIAMENTO REMOTO. Brasilia (2012). Disponível em: http://memoria.cnpq.br/documents/10157/56b578c4-0fd5-4b9f-b82a-e9693e4f69d8.2012.

[72] SLATER, P.N. Remote Sensing, optics and optical systems. New York, Addison-Wesley, 1980.

[73] MORAES, E. M. L. PONZONI, N. F. J. INTRODUÇÃO AO SENSORIAMENTO

REMOTO. São José dos Campos 2001. Disponível em: http://www.dpi.inpe.br/Miguel/AlunosPG/Jarvis/SR_DPI7.pdf.2001.

[74] JAMES B Campbell e Randolph H Wynne. Introduction to remote sensing. Guilford press, 2011.

[75] FILHO, R. A. Using dual-polarized ALOS PALSAR data for detecting new fronts of deforestation in the Brazilian Amazônia. International Journal of Remote Sensing, 30(14):3735–3743, 2009.

[76] GUIMARÃES, U. S. Datasets for geomorphological mapping in the eastern of Marajo Island, Amazon coast. Geomorphology, 350:106934, February 2020.

[77] STEFAN MUCKENHUBER, Anton Andreevich Korosov, e Stein Sandven. Open-source feature-tracking algorithm for sea ice drift retrieval from Sentinel-1 SAR imagery. The Cryosphere, 10(2):913–925, 2016.

[78] MUHAMMAD A. MAPPING DEFORESTATION IN PERMANENT FOREST RESERVE OF PENINSULAR MALAYSIA WITH MULTI-TEMPORAL 74 SAR IMAGERY AND U-NET BASED SEMANTIC SEGMENTATION. Malaysian Journal of Computer Science, pages 15–34, 2021.

[79] ADARME, M. O. Improving Deforestation Detection on Tropical Rainforests Using Sentinel-1 Data and Convolutional Neural Networks. Remote Sensing, 14(14):3290, 2022.

[80] SOLORZANO, J. V. Deforestation detection using a spatio-temporal deep learning approach with synthetic aperture radar and multispectral images. ISPRS Journal of Photogrammetry and Remote Sensing, 199:87–101, 2023.

[81] FONSECA, L. M.G. Earth Observation Applications in Brazil with Focus on the CBERS Program. IEEE Geoscience and Remote Sensing Magazine, 2(2):53–55, 2014.

[82] EPIPHANIO, J. C. N. Satélites brasileiros de observação da terra: balanço e perspectivas. Proc. XVI Simpósio Brasileiro de Sensoriamento Remoto, 2013.

[83] XIAO X. Z. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. IEEE Geoscience and Remote Sensing Magazine, 73 5(4):8–36. Conference Name: IEEE Geoscience and Remote Sensing Magazine. 2017.

[84] TAVARES, P. A. Integration of sentinel-1 and sentinel-2 for classification and LULC mapping in the urban area of Belém, eastern Brazilian Amazon. Sensors, 19(5):1140, 2019.

[85] ADARME, M. O. Juan Doblas Prieto, Raul Queiroz Feitosa, e Cláudio Aparecido De Almeida. Improving Deforestation Detection on Tropical Rainforests Using Sentinel-1 Data and Convolutional Neural Networks. Remote Sensing, 14(14):3290, 2022.

[86] KULKARNI, S. C. Pixel level fusion techniques for sar and optical images: A review. Information Fusion, 59:13–29, 2020.

[87] UNION of Concerned Scientists. Ucs satellite database. https://www.ucsusa.org/ resources/satellite-database, 2023.

[88] EFREMENKO, D. Foundations of Atmospheric Remote Sensing. Springer International Publishing, Cham, 2021.

[89] FITRZYK, M. ESA Copernicus Sentinel1 Exploitation Activities. In IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium, pages 5389–5392, 2019.

[90] ALASKA Satellite Facility Discovery Team. ASF Discovery: asf search. https:// github.com/asfadmin/Discovery-asf_search, 2023.

[91] MOREIRA, A.A tutorial on synthetic aperture radar. IEEE Geoscience and remote sensing magazine, 1(1):6–43, 2013.

[92] MAHMUDUR, M. Mapping tropical forest cover and deforestation using synthetic aperture radar (SAR) images. Applied Geomatics, 2:113–121, 2010.

[93] FONTES, J. C. O uso dos veículos não tripulados no monitoramento ambiental na amazônia. Revista de Direito e Sustentabilidade, 2(2):149–164, 2016.

[94] GOMES, L. F. The use of air laser scanning as a monitoring tool of structural variables of selective logging in the Amazon. PhD thesis, Universidade de Brasilia, 2022.

[95] SILVA, L. G. Integrated use of Sentinel-1 and Sentinel-2 data and open-source machine learning algorithms for land cover mapping in a Mediterranean region. European Journal Of Remote Sensing, 2022.

[96] GALVÃO, Jonilson Michel Fontes. Classificação de Regiões em Imagens do Satélite Sentinel 2 através de Inteligência Artificial. 2023.

[97] RAIYANI, K. Sentinel-2 Image Scene Classification: a comparison between sen2cor and a machine learning approach. Remote Sensing. 2021.

[98] ABDI, A. M. Land cover and land use classification performance of machine learning algorithms in a boreal landscape using Sentinel-2 data. Giscience & Remote Sensing, v. ‘57, n. 1, p. 1-20, 22 ago. 2019.

[99] MALINOWSKI, R.; LEWIŃSKI, S.; RYBICKI, M.; GROMNY, E.; JENEROWICZ, M.; KRUPIŃSKI, M.; NOWAKOWSKI, A.; WOJTKOWSKI, C.; KRUPIŃSKI, M.; KRÄTZSCHMAR, E. Automated Production of a Land Cover/Use Map of Europe Based on Sentinel-2 Imagery. Remote Sensing, v. 12, n. 21, p. 3523, 27 out. 2020.

[100] PRASAD, P.; LOVESON, V. J.; CHANDRA, P.; KOTHA, M. Evaluation and comparison of the earth observing sensors in land cover/land use studies using machine learning algorithms. Ecological Informatics, v. 68, p. 101522, maio 2022.

[101] DABIJA, A.; KLUCZEK, M.; ZAGAJEWSKI, B.; RACZKO, E.; KYCKO, M.; ALSULTTANI, A. H.; TARDÀ, A.; PINEDA, L.; CORBERA, J.. Comparison of Support Vector Machines and Random Forests for Corine Land Cover Mapping. Remote Sensing, v. 13, n. 4, p. 777, 20 fev. 2021.

[102] CLARK, M. L. Comparison of simulated hyperspectral HyspIRI and multispectral Landsat 8 and Sentinel-2 imagery for multi-seasonal, regional land-cover mapping. Remote Sensing Of Environment, v. 200, p. 311-325, out. 2017.

[103] XIE, G.; NICULESCU, S. Mapping and Monitoring of Land Cover/Land Use (LCLU) Changes in the Crozon Peninsula (Brittany, France) from 2007 to 2018 by Machine Learning Algorithms (Support Vector Machine, Random Forest, and Convolutional Neural Network) and by Post-classification Comparison (PCC). Remote Sensing, v. 13, n. 19, p. 3899, 29 set. 2021.

[104] FILHO, S. E. B. Ocorrências de focos de calor no estado de Rondônia em 2007. Sociedade & Natureza, Uberlândia, 21 (2): 123- 140, ago. 2009.

[105] FLORENZANO, T. G. Iniciação em sensoriamento remoto. 2. ed. São Paulo: Oficina de Textos, 2007.

[106] PASTRO, L. A.; DICKMN, C. R.; LETNIC, M. Burning for biodiversity or burning biodiversity? Prescribed burn vs.wildfire impacts on plants, lizards, and mammals. Ecological Applications, Washington, v.21, n.8, p.3238-3253, 2011.

[107] CBMGO. Corpo de Bombeiros Militar do Estado de Goiás. Manual Operacional de Bombeiros: combate a incêndio urbano. Goiania: CBMGO, 2017a.

[108] CBMGO. Corpo de Bombeiros Militar do Estado de Goiás. Manual Operacional de Bombeiros: prevenção e combate a incêndios florestais. Goiania: CBMGO, 2017b.

[109] CBMTO. Corpo de Bombeiros Militar do Estado do Tocantins. Portaria n.

001/2019/CEDEC, de 06 de maio de 2019. Diário Oficial Nº 5.355, de 10 de maio de 2019. Palmas: CBMTO,2019.

[110] BARROS, K. L. C.; SILVA, E. M. R.; MENDONÇA, B. A. F.; PEREIRA, M. G.; FRANCELINO, M. R. Análise temporal da cobertura e uso da terra do assentamento rural fazenda do salto – Barra Mansa, RJ. Revista Geo UERJ, Rio de Janeiro, n.33, p.e31889, 2018.

[111] ZHANG, L. Deep learning for remote sensing data: A technical tutorial on the state of the art. IEEE Geoscience and Remote Sensing Magazine, 4(2):22–40, 2016. Conference Name: IEEE Geoscience and Remote Sensing Magazine. 2016.

[112] JIAXIN, L. Deep learning in multimodal remote sensing data fusion: A comprehensive review.2020.

[113] CARLOS, E. Effects of land use change on water availability and water efficiency in the temperate basins of south-central Chile. Journal of King Saud University-Science, 33(8):101650, 2021.

[114] SINGH, M. P. A simple data preprocessing and postprocessing techniques for SVM classifier of remote sensing multispectral image classification. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing, 15:7248–7262, 2022.

[115] PETER, N. Inteligência artificial. Rio de Janeiro: Grupo GEN, 2013.

[116] BARBOSA, Lucia Martins; PORTES, Luiza Alves Ferreira. Inteligência artificial. ASSOCIE-SE À ABT, p. 16, 2023.

[117] GONÇALVES, L. S. FANTAZIA, G. S. Inteligência artificial na indústria 4.0. E-Acadêmica, 4(2), e2642485. https://doi.org/10.52076/eacad-v4i2.485.2023.

[118] LIMA–C, M. Pós-graduação em Sistemas de Informação Disciplina: Aprendizado de Máquina SYLABUS.2023

[119] BRITO, M. S. UTILIZAÇÃO DE ALGORITMOS DE APRENDIZAGEM DE MÁQUINA PARA CLASSIFICAÇÃO DE IMAGENS E AVALIAÇÃO DA DEGRADAÇÃO AMBIENTAL NA ILHA DE COTIJUBA (PA).2023.

[120] GERON, A. Mãos à Obra Aprendizado de Máquina com Scikit-Learn, Keras e TensorFlow, Starlin Alta Editora e Consultoria Eireli 2021.

[121] SIQUEIRA, G. S. Análise de aplicação de algoritmos de aprendizado de máquina e análise técnica na predição de tendência de ações da bolsa de valores.2023.

[122] BIAU, G., SCORNET, E. A random forest guided tour. TEST, v. 25,p. 197–227, 2016.

[123] LORENZETT, C. D. C; TELOCKEN, A. V. Estudo Comparativo entre os algoritmos de Mineração de Dados Random Forest e J48 na tomada de Decisão. Simpósio de Pesquisa e Desenvolvimento em Computação, v. 2, n. 1, 2016.

[124] PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. Journal of Machine Learning Research, v. 12, p. 2825–2830, 2011.

[125] BATISTA, G. A.et al. Identificação De cultivares de feijão caupi a partir de imagens digitais de sementes e técnicas de inteligência artificial. 2023.

[126] GOLDBERGER, J. et al. Neighbourhood components analysis. In: SAUL, L.; WEISS, Y.; BOTTOU, L. (Ed.). Advances in Neural Information Processing Systems. MIT Press, 2004.

[127] RAMOS, C. Aprendizado de máquina como ferramenta para o prognóstico de pacientes em coma usando sinais eletroencefalográficos no espectro de 1 a 100 Hz. 2022. Universidade Federal de Uberlândia, 2022. http://doi.org/10.14393/ufu.te.2022.

[128] SILVA, G. L. Avaliação do desempenho de classificadores na discriminação de indivíduos adultos e idosos saudáveis a partir da função manual. 2023. 81 f. Tese (Doutorado

em Engenharia Elétrica) - Universidade Federal de Uberlândia, Uberlândia, 2023. DOI http://doi.org/10.14393/ufu.te.2023.7042.2023.

[129] LECUN, Y. Deep learning. nature, v. 521, n. 7553, p. 436-444, 2015.

[130] GOODFELLOW, I. Deep learning. MIT press, 2016.

[131] BRAGAGNOLO, L. Landslide susceptibility mapping with r. landslide: A free open-source Gis-integrated tool based on Artificial Networks.

[132] BRUSCHI, M. Deep learning aplicada a segmentação semântica semiautomática de cicatrizes de deslizamentos de terra.2022.

[133] DO VALE, I. G. Classificação de Imagens hiper espectrais utilizando redes neurais convolucionais para caracterização da ocupação desordenada do solo sobre um recorte do Parque Nacional da Tijuca, RJ. Revista Brasileira de Geografia Física, v. 15, n. 1, p. 561-571, 2022.

[134] KAYET, N.; PATHAK, K. Forest health assessment for geoenvironmental planning and management in hilltop mining areas using Hyperion and Landsat data. Ecological Indicators, 106,105471.2019.

[135] SHU L. Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2018.

[136] COSTA, T. K. O. Técnicas de segmentação de imagens através de redes neurais convolucionais. 2023.

[137] PRESNER, D. H. Identificação de espécies de plantas utilizando auto encoder Convolucional e aprendizagem não supervisionada. 2022. Dissertação (Mestrado em Computação Aplicada) - Universidade de Estadual de Ponta Grossa, Ponta Grossa, 2022.

[138] MASTELLA, A. F. M. Acurácia temática para classificação de imagens utilizando abordagens por pixel e por objetos. Revista Brasileira de Cartografia, v. 70, n. 5, p. 1618-1643, 2018.

[139] CONGALTON, R. G.; GREEN, K. Assessing the accuracy of remotely sensed data: principles and practices. Lewis Publishers, Boca Raton, FL, 1999.

[140] DIETTERICH, T. G. Ensemble methods in machine learning. In: SPRINGER. International workshop on multiple classifier systems. [S.l.], 2000. p. 1–15. Citado na página 20.2000.

[141] RODRIGUES, P. G. Estudo comparativo de abordagens computacionais para classificação de imagens de satélite da Amazônia. Trabalho de Conclusão de Curso (Bacharelado em Sistemas de Informação) – Universidade Tecnológica Federal do Paraná, Curitiba, 2020. (http://repositorio.utfpr.edu.br/jspui/handle/1/28572).2020.

[142] KAIMING H. Proceedings of the IEEE International Conference on Computer Vision (ICCV), 2017.

[143] LONG, j. E. S. Fully convolutional networks for semantic segmentation. In CVPR, 2015.

[144] NAJAFI, P.; FEIZIZADEH, B.; NAVID, H.. A Comparative Approach of Fuzzy Object Based Image Analysis and Machine Learning Techniques Which Are Applied to Crop Residue Cover Mapping by Using Sentinel-2 Satellite and UAV Imagery. Remote Sensing, v. 13, n. 5, p. 937, 3 mar. 2021.

[145] VASILAKOS, C.; KAVROUDAKIS, D.; GEORGANTA, A. Machine Learning Classification Ensemble of Multitemporal Sentinel-2 Images: the case of a mixed mediterranean ecosystem. Remote Sensing, v. 12, n. 12, p. 2005, 22 jun. 2020.

[146] GHAYOUR, L.; NESHAT, A.; PARYANI, S.; SHAHABI, H.; SHIRZADI, A.; CHEN, W.;

AL-ANSARI, N.; GEERTSEMA, M.; AMIRI, M. P.; GHOLAMNIA, M. Performance Evaluation of Sentinel-2 and Landsat 8 OLI Data for Land Cover/Use Classification Using a Comparison between Machine Learning Algorithms. Remote Sensing, v. 13, n. 7, p. 1349, 1 abr. 2021.

[147] MUSHTAQ, F.; MAHMOOD, K.; HAMID, M. C.; TUFAIL, R. A Comparative Study of Support Vector Machine and Maximum Likelihood Classification to Extract Land Cover of Lahore District, Punjab, Pakistan. Pakistan Journal Of Scientific & Industrial Research Series A: Physical Sciences, v. 64, n. 3, p. 265- 274, 29 set. 2021.

[148] EBRAHIMY, H.; NABOUREH, A.; FEIZIZADEH, B.; ARYAL, J.; GHORBANZADEH, O. Integration of Sentinel-1 and Sentinel-2 Data with the G-SMOTE Technique for Boosting Land Cover Classification Accuracy. Applied Sciences, v. 11, n. 21, p. 10309, 3 nov. 2021.

[149] AGUILERA, M. A. Z. Classication Of Land-Cover Through Machine Learning Algorithms For Fusion Of Sentinel-2a And Planet scope Imagery. 2020 IEEE Latin American GRSS & ISPRS Remote Sensing Conference (LAGIRS), pp. 246- 253, 2020.

[150] SIMONYAN, K.; ZISSERMAN, A. Very Deep Convolutional Networks for Large Scale Image Recognition. .2015.

[151] SHI, G. Use satellite data to track the human footprint in the amazon rainforest. 2017.

[152] GARDNER, D.; NICHOLS, D. Multi-label classification of satellite images with deep learning. 2017.

[153] KOGUCHI, C. et al. Understanding the amazon rainforest from space using neural networks. 2018.

[154] SHENDRYK, I. et al. Deep learning-a new approach for multi-label scene classification in planet scope and sentinel-2 imagery. In: IEEE. IGARSS 2018-2018 IEEE International Geoscience and Remote Sensing Symposium. [S.l.], 2018. p. 1116–1119. 2018.

[155] SACADURA, J. P. V. C. Segmentação de imagens multiespectrais de alta resolução utilizando o modelo U-Net para cartografia de uso do solo, 2021.

[156] QGIS Development Team. QGIS Geographic Information System. QGIS Association, 2023.

[157] JORDAN, M.I.; MITCHELL, T.M. Machine Learning: Trends, Perspectives, and Prospects. Science 2015, 349, 255–260. 2015.

[158] KARASIAK, N. DZETSAKA: Classification Plugin for Qgis. Available online: https://github.com/nkarasiak/dzetsaka.2022.

[159] KARASIAK, N.; PERBET, P. Remote Sensing of Distinctive Vegetation in Guiana Amazonian Park. QGIS Appl. Agric. For. 2018, 2, 215–245.2018.

[160] BREIMAN, L. RANDOM FORESTS. Mach. Learn. 2001, 45, 5–32. [Cross Ref].2001.

[161] GHOSH, A.; SHARMA, R.; JOSHI, P.K. Random Forest Classification of Urban Landscape Using Landsat Archive and Ancillary Data: Combining Seasonal Maps with Decision Level Fusion. 2014.

[162] GÉRON, A. Hands-On Machine Learning with Scikit-Learn and TensorFlow: Concepts, Tools, and Techniques to Build Intelligent Systems. first. [S. l.]: O'Reilly, 2017.

[163] BELGIU, M.; DRĂGUŢ, L. Random Forest in remote sensing: A review of applications and future directions. ISPRS J. Photogramm. Remote Sens. v. 114, p. 24–31, 2016.

[164] PRODES. Monitoramento do Desmatamento da Floresta Amazônica Brasileira por Satélite. 2020.

[165] PROGRAMA QUEIMADAS. Sistemas de Monitoramento. 2020. Disponível em http://queimadas.dgi.inpe.br/queimadas/portal/.2020.

[166] INPE. Dados Abertos. Disponível em http://www.inpe.br/dados_abertos/. 2020.

[167] PANTALEÃO, E; SCOFIELD, G. B. Comparação entre medidas de acurácia de classificação para imagens do satélite ALOS. XIV Simpósio Bras Sensoriamento Remoto, p. 7039-7046, 2009.

[168] COSTA, W. S. Segmentação de imagens de sensoriamento remoto baseada em séries temporais e DTW / Wanderson Santos Costa. – São José dos Campos : INPE, 2019. xxvi + 97 p. ; (sid.inpe.br/mtc-m21c/2019/03.29.13.33-TDI) Tese (Doutorado em Computação Aplicada) – Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2019. Orientadores : Drs. Leila Maria Garcia Fonseca, e Thales Sehn Körting. 2019.

[169] WHATELY, M.; CAMPANILI, M. Programa Municípios Verdes: lições aprendidas e desafios para 2013/2014. Belém/PA, 2013.

[170] BARROSO, L. R. MELLO, P. P. C. COMO SALVAR A AMAZÔNIA: POR QUE A FLORESTA DE PÉ VALE MAIS DO QUE DERRUBADA. Revista de Direito da Cidade vol. 12, nº 2. ISSN 2317-7721 DOI: 10.12957/rdc.2020.50890. 2020.

[171] DESMATAMENTO DA AMAZÔNIA EM ABRIL DE 2020 É O MAIOR EM DEZ ANOS. (2020). Disponível em: https://ds.saudeindigena.icict.fiocruz.br/handle/bvs/2099.2020.

[172] ESTADÃO CONTEÚDO. Ministério do Meio Ambiente reduz verba de combate à mudança climática. Exame, 7 mai. 2019.

[173] KALUNGA, B. Desmatamento na Amazônia é ideológico, diz economista Ricardo Abramovay. 2020.

[174] BRASIL. Ministério do Meio Ambiente. Lista de Municípios Prioritários da Amazônia, 2017b. Disponível em: https://www.gov.br/mma/pt-br.2017.

[175] NEVES, E. M. S. C. et al. O processo de municipalização da estratégia de prevenção e combate ao desmatamento na Amazônia: estudos de casos sobre municípios integrantes da Lista de Municípios Prioritários do Ministério do Meio Ambiente, 2015.

[176] INSTITUTO NACIONAL DE PESQUISAS ESPACIAIS (INPE). Prodes – Desmatamento nos municípios. 2017a.

[177] FONSECA, A., JUSTINO, M., CARDOSO, D., RIBEIRO, J., SALOMÃO, R., SOUZA, C., VERÍSSIMO, A. Boletim do desmatamento da Amazônia Brasileira (junho-2019). SAD (p. 1). Belém-PA: Imazon.2019.

[178] BRASIL. Ministério do Meio Ambiente e Sustentabilidade. Relatório de balanço da 3ª fase do PPCDAM (versão preliminar). 2016.

[179] BRASIL. Ministério do Meio Ambiente. Plano de Prevenção e Controle do Desmatamento na Amazônia Brasileira, 2017a.

[180] PLANO DE AÇÃO PARA PREVENÇÃO E CONTROLE DO DESMATAMENTO NA AMAZÔNIA BRASILEIRA. BALANÇO DE EXECUÇÃO 2018. PPCDAm e PPCerrado 2016-2020.

[181] COSTA, J. P., SANTOS, L. C. S., RIOS, J. M., RODRIGUES, A. W., DIAS NETO, O. C., PRADO JÚNIOR, J., Vale, V. S., 2019. Estrutura e diversidade de trechos de Cerrado sensu stricto às margens de rodovias no estado de Minas Gerais. Ciência Florestal 29, 698-714.2019.

[182] PROGRAMA MUNICÍPIOS VERDES (PMV). Diagnóstico da dinâmica do desmatamento nos municípios da base local Redenção. 2016b.

[183] ALENCAR, A.; PEREIRA, C. CASTRO I.; CARDOSO, A., SOUZA L., COSTA, R., BENTES, A. J., STELLA, O., AZEVEDO, A., GOMES, J., NOVAES, R. 2016. Desmatamento nos Assentamentos da Amazônia: Histórico, Tendências e Oportunidades. IPAM, Brasília, DF,

93p.2016.

[184] PRODES. Programa de Monitoramento da Floresta Amazônica Brasileira por Satélite. Ministério do Meio Ambiente – MMA, Instituto Nacional de Pesquisas Espaciais – Inpe, do Ministério da Ciência e Tecnologia. Disponível em: <http://www.obt.inpe.br/prodes>.2022.

[185] MORAIS, A. R. S; SANTOS, M. M. C. Campanha de Sensibilização e Percepção Ambiental Sobre as Queimadas: Uma Experiência nos Bairros Areal e Mato Grosso – Porto Velho / Rondônia. 2018. 25 f. TCC (Graduação) - Curso de Ciências Biológica, Centro Universitário São Lucas, Porto Velho, 2018.

[186] SANTOS, T. O; ANDRADE FILHO, V. S; ROCHA, V. M.; MENEZES, J. S. Os Impactos do Desmatamento e Queimadas de Origem Antrópica Sobre o Clima da Amazônia Brasileira: Um Estudo de Revisão. Revista Geografia Acadêmica, v.11, n.2, 2017a.

[187] BANDEIRA, C. FLORIANO, E. P. Avaliação de impacto ambiental de rodovias, Caderno Didático nº 8, 1ª ed./ Clarice Bandeira, Eduardo P. Floriano. Santa Rosa, 2004.

[188] GOMES, M. M., VITÓRIA, C. F., SILVA, E. R., ALMEIDA, J. R., 2019. Avaliação de impactos ambientais da duplicação da BR 101 RJ/Norte, trecho compreendido entre o Km 144,2 e 190,3. Revista Internacional de Ciências 9, 22- 34.2019.

[189] ANDERSEN, L. E. e REIS, E. J. Deforestation, Development, and Government Policy in the Brazilian Amazon: An Econometric Analysis. Texto para Discussão n. 513. Rio de Janeiro: IPEA, set. 1997.

[190] SANTOS, L. A. C.. Utilização dos dados do Cadastro Ambiental Rural na análise de conflitos de uso do solo em Áreas de Preservação Permanente. Tecnia: Revista de Educação, Ciência e Tecnologia do IFG, Goiânia, v.3, n.1, 2018c.

[191] PLETSCH, M. A. J. S.; PENHA, T. V.; SILVA JUNIOR, C. H. L.; KORTING, T. S.; ARAGÃOP, L. E. O. C.; ANDERSON, L. O.. Integração do algoritmo FMASK ao modelo linear de mistura espectral como subsídio à detecção de áreas queimadas na Amazônia brasileira. Revista Brasileira de Cartografia, v.70, n.2, p.696-724, 2018.

[192] SANTOS, P. R.; PEREIRA, G.; CARDOZO, F. S.; RAMOS, R. C.; FERREIIRA, A. B. R.; RESENDE, F. C.. Análise das queimadas no cerrado e sua relaão com o NDVI para os anos de 2000 a 2014. Revista de Geografia, Recife, v.35, n.2, p.134-157, 2018b.

[193] SANTOS, R. S.; BARRETO, P. A. B.; SCORIZA, R. N.. Fungos micorrízicos arbusculares e serapilheira como indicadores do efeito de borda em fragmento de floresta estacional. Ciência Florestal, Santa Maria, v.28, n.1, p.324-335, 2018a.

[194] FONSECA-MORELLO, T.; RAMOS, R.; STEIL, L.; PARRY, L.; BARLOW, J.; MARKUSSON, N.; FERREIRA, A.. Queimadas e incêndios florestais na Amazônia brasileira: por que as políticas públicas têm efeito limitado?. Ambiente & Sociedade, Campinas, v.20, n.4, p.19-40, 2017.

[195] CLEMENTE, S.; OLIVEIRA JÚNIOR, J. F.; LOUZADA, M. A. P..Focos de calor do bioma Mata Atlântica no estado do Rio de Janeiro: uma abordagem de gestão e legislação ambiental. Revista de Ciências Agroambientais, Alta Floresta, v.15, n.2,p.158-174, 2017.

[196] KOHLHEPP, G.. O programa piloto internacional de proteção das florestas tropicais no Brasil (1993-2008): as primeiras estratégias da politica ambiental de desenvolvimento regional para a Amazônia brasileira. Revista NERA: Núcleo de Estudos, Pesquisas e Projetos de Reforma Agrária, Presidente Prudente, v.21, n.42, p.308-330, 2018.

[197] ASSUNÇÃO, J., GANDOUR, C. C. e ROCHA, R. Deforestation slowdown in the Legal Amazon: prices or policies? CPI. Rio de Janeiro: [s.n.]. 2012.

[198] SAMPAIO, A. C. F., GERMANO, P. J. M. T., ANGELIS, B. L. D., NOCCHI, M. J., 2018. Classificação ambiental dos fragmentos florestais da área rural do município de maringá-pr,

brasil: primeiras etapas. Revista em Agronegócio e Meio Ambiente 11, 253-276.2018.

[199] MYERS, E. N. Policies to Reduce Emissions from Deforestation and Degradation (REDD): An examination of the issues facing the incorporation of REDD into market-based climate policies in Tropical Forests. Discussion Paper RFF DP 07-50. dez. 2007.

[200] STOKEY, N. Are There Limits to Growth? International Economic Review, v. 39, n. 1, p. 1-31, 1998.

[201] IGLIORI, D.C. Deforestation, Growth and Agglomeration Effects: Evidence from Agriculture in the Brazilian Amazon. University of Cambridge, Department of Land Economy (Texto para Discussão, 28) 2008.

[202] MELLO, N. G. R. Evolução do Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (Brasileira). Revista do Instituto de Estudos Brasileiros, Brasil, n. 66, p. 108-129, abr. 2017.

[203] SANTOS. J.S; OLIVEIRA, A.P. A ocupação territorial da Amazônia e do sudeste Paraense: Políticas e projetos de desenvolvimento, reforma agrária e impactos socioambientais. DOI:10.34117/bjdv6n4-132 Braz. J. of Develop., Curitiba, v. 6, n. 4, p. 18424-18439, ISSN 2525-8761. 2020.

[204] RODRIGUES, R. Uma discussão nomenclatural das formações ciliares. In: R.R. RODRIGUES & H.F. LEITÃO FILHO. Matas ciliares: conservação e recuperação. São Paulo, EDUSP. p. 91-99, 2004.

[205] DE ZEN, S.; MENEZES, S.M.; CARVALHO, T.B. Perspectivas de consumo de carne bovina no Brasil. In: CONGRESSO DA SOCIEDADE BRASILEIRA DE ECONOMIA, ADMINISTRAÇÃO E SOCIOLOGIA RURAL, 2008, Piracicaba. Anais... Acre: SOBER, 2008.

[206] SHERRIL, E. I. Padrões de Uso do Solo, Desmatamento na Amazônia e seus Impactos Globais: Um modelo Econômico-Ecológico de Dinâmica Regional. In: III Encontro da Sociedade Brasileira de Economia Ecológica. Anais... Recife: Nov. 1999, p. 1- 18.1999.

[207] JARAMILLO, C. F. e KELLY, T. Deforestation ad Property Rights in forest Resource Policy in Latin America. Washington, D.C.: Inter-American Development Bank. 1999. Disponível em: <http://idbdocs.iadb.org/wsdocs/ getdocument.aspx?docnum=359769>.1999.

[208] CORREIA, F. W. S.; ALVALÁ, R. C. S.; MANZI, A. O. Modeling the impacts of land cover change in Amazonia: a regional climate model (RCM) simulation study. Theoretical and Applied Climatology, v. 93, p. 225-244, doi: 10.1007/s00704-007-0335-z, 2008.

[209] LEJEUNE, Q.; DAVIN, E. L.; GUILLOD, B. P.; SENEVIRATNE, S. I. Influence of Amazonian deforestation on the future evolution of regional surface fluxes, circulation, surface temperature and precipitation. Climate Dynamics, v. 44, n. 9-10, p. 2769-2786, 2015.

[210] SILVA, M. E. S.; PEREIRA, G.; DA ROCHA, R. P. Local and remote climatic impacts due to land use degradation in the Amazon “Arco of Deforestation”. Theoretical and Applied Climatology, v. 125, p. 609–623, 2016.

[211] GEDNEY, N.; VALDES, P. J. The Effect of Amazonian Deforestation on the Northern Hemisphere Circulation and Climate. Geophysical Research Letters, v. 27, n. 19, p. 3053-3056, 2000.

[212] WERTH, D.; AVISSAR, R. The local and global effects of Amazon deforestation. Journal of Geophysical Research: Atmospheres, v. 107, n. D20, p. LBA 55-1–LBA 55-8, doi: 10.1029/2001JD000717, 2002.

[213] CORREIA, F. W. S.; MANZI, A. O.; CÂNDIDO, L. A.; SANTOS, R. M. N.; PAULIQUEVIS, T. Balanço de umidade na Amazônia e sua sensibilidade às mudanças na cobertura vegetal. Ciência e Cultura, v. 59, n. 3, p. 39-43, 2007.

[214] FEARNSIDE, P. M. Desmatamento na Amazônia: dinâmica, impactos e controle. Acta Amazônica, v. 36, n. 3, p. 395-400, 2006.

[215] ZEMP, D. C.; SCHLEUSSNER, C. F.; BARBOSA, H. M. J.; RAMMIG, A. Deforestation effects on Amazon Forest resilience. Geophysical Research Letters, v. 44, p. 1-9, 2017.

[216] WIENS, J. J. Climate-Related Local Extinctions Are Already Widespread among Plant and Animal Species. PLOS Biology, v. 14, n. 12, p. 1-18, 2016.

[217] NOBRE, S. C. Modelos e cenários para a Amazônia: o papel da ciência mudanças climáticas globais: possíveis impactos nos ecossistemas do país. Parcerias Estratégicas, n. 12, p. 240-258, 2001.

[218] NOBRE, C. A.; MARENGO, J. A.; ARTAXO, P. Understanding the Climate of Amazonia: Progress From LBA. In: KELLER M.; BUSTAMANTE M.; GASH J.; DIAS, P. S. (Eds). Amazonia and Global Change. Geophysical Monograph Series, v. 186, p. 145-147, 2009a.

[219] MYERS, E. N. Policies to Reduce Emissions from Deforestation and Degradation (REDD): An examination of the issues facing the incorporation of REDD into market-based climate policies in Tropical Forests. Discussion Paper RFF DP 07-50. dez. 2007.

[220] STOKEY, N. Are There Limits to Growth?. International Economic Review, v. 39, n. 1, p. 1-31, 1998.

[221] LOVEJOY, Thomas E.; NOBRE. Carlos. Amazon Tipping Point. Science Advances, 2018.

[222] SOARES-FILHO, B. et al. Modelling conservation in the Amazon basin. Nature, v. 440, p. 520-523, 2006.

[223] MALHI, Y. et al. Evolução do Plano de Ação para Prevenção e Controle do Desmatamento na Amazônia Legal (Brasileira). Revista do Instituto de Estudos Brasileiros, Brasil, n. 66, p. 108-129, abr. 2017.

[224] MAGIRI, D. S; FRANÇA C. A. Classificação de Imagens de Satélite com Redes Neurais Convolucionais Departamento de Engenharia Elétrica da Universidade Federal de São Carlos. 2023.

[225] CORDEIRO, A. F. Classificação de imagens de satélite da Floresta Amazônica utilizando processamento de imagem e Aprendizado de Máquina.2023.

[226] SOUZA, E. P. O. Análise comparativa de modelos de machine learning e convolutional neural networks na detecção de falhas em máquinas rotativas. 2024.

[227] SENS, D. F. Rede Neural Convolucional para classificação de imagens SAR de desflorestamento na Amazônia. Universidade de Brasília – UnB. 2021.

[228] SHORTEN, C.; KHOSHGOFTAAR, T. M. A survey on image data augmentation for deep learning. Journal of Big Data, 6(1):60.2019.

[229] MILANI, F.C.C. CARNEIRO, V. D. Avaliação de Desempenho de Classificadores em Imagens CBERS-04A E SENTINEL-2 do município de Piracicaba – SP. XIV ENCONTRO DE PÓS-GRADUAÇÃO EM PESQUISA E GEOGRAFIA. 2021.b

[230] ARABI, B. et al. Remote sensing of water constituent concentrations using time series of insitu hyperspectral measurements in the Wadden Sea. Remote Sensing of Environment, v. 216, n. November, p. 154–170, 2018.

[231] LANDIS, J.R.; & KOCH, G.G. The measurements of observer agreement for categorical data. Biometrics, v. 33, p. 159-174. https://doi.org/10.2307/2529310LEE. 1977