



**PREVISÃO DE RISCO  
DE DESMATAMENTO COM BASE  
EM ALGORITMOS DE *MACHINE LEARNING***

**PAULO GUINANCIO BACCHINI DE ARAÚJO LIMA**

**TRABALHO DE CONCLUSÃO DE CURSO DE EM ENGENHARIA ELÉTRICA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**FACULDADE DE TECNOLOGIA**

# UNIVERSIDADE DE BRASÍLIA

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**PREVISÃO DE RISCO  
DE DESMATAMENTO COM BASE  
EM ALGORITMOS DE *MACHINE LEARNING***

**PAULO GUINANCIO BACCHINI DE ARAÚJO LIMA**

**Orientador: PROF. DR. EDSON MINTSU HUNG, ENE/UNB**

**TRABALHO DE CONCLUSÃO DE CURSO DE EM ENGENHARIA ELÉTRICA**

**PUBLICAÇÃO PPGENE.DM - XXX/AAAA**  
**BRASÍLIA-DF, 27 DE JULHO DE 2023.**

**UNIVERSIDADE DE BRASÍLIA  
FACULDADE DE TECNOLOGIA  
DEPARTAMENTO DE ENGENHARIA ELÉTRICA**

**PREVISÃO DE RISCO  
DE DESMATAMENTO COM BASE  
EM ALGORITMOS DE *MACHINE LEARNING***

**PAULO GUINANCIO BACCHINI DE ARAÚJO LIMA**

TRABALHO DE CONCLUSÃO DE CURSO DE ACADÊMICO SUBMETIDA AO DEPARTAMENTO DE ENGENHARIA ELÉTRICA DA FACULDADE DE TECNOLOGIA DA UNIVERSIDADE DE BRASÍLIA, COMO PARTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE EM ENGENHARIA ELÉTRICA.

**APROVADA POR:**

Prof. Dr. Edson Mintsu Hung, ENE/UnB  
Orientador

Prof. Eduardo Peixoto Fernandes da Silva, ENE/UnB  
Examinador interno

Dr. Renam Castro da Silva  
Examinador Externo

**BRASÍLIA, 27 DE JULHO DE 2023.**

## **FICHA CATALOGRÁFICA**

PAULO GUINANCIO BACCHINI DE ARAÚJO LIMA

**Previsão de Risco de desmatamento com base em algoritmos de *Machine Learning***

**2023xv, 48p., 201x297 mm**

(ENE/FT/UnB, , Engenharia Elétrica, 2023)

Trabalho de Conclusão de Curso de - Universidade de Brasília

Faculdade de Tecnologia - Departamento de Engenharia Elétrica

## **REFERÊNCIA BIBLIOGRÁFICA**

PAULO GUINANCIO BACCHINI DE ARAÚJO LIMA (2023) Previsão de Risco de desmatamento com base em algoritmos de *Machine Learning*. Trabalho de Conclusão de Curso de em Engenharia Elétrica, Publicação xxx/AAAA, Departamento de Engenharia Elétrica, Universidade de Brasília, Brasília, DF, 48p.

## **CESSÃO DE DIREITOS**

AUTOR: Paulo Guinancio Bacchini de Araújo Lima

TÍTULO: Previsão de Risco de desmatamento com base em algoritmos de *Machine Learning*.

GRAU: ANO: 2023

É concedida à Universidade de Brasília permissão para reproduzir cópias desta trabalho de conclusão de curso de e para emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. O autor se reserva a outros direitos de publicação e nenhuma parte desta trabalho de conclusão de curso de pode ser reproduzida sem a autorização por escrito do autor.

---

Paulo Guinancio Bacchini de Araújo Lima

SQN 203 Bloco A apt 505

# Agradecimentos

Gostaria de expressar minha sincera gratidão a todos os que contribuíram para a conclusão deste estudo. Seu apoio, orientação e incentivo foram inestimáveis ao longo dessa jornada.

Em primeiro lugar, agradeço profundamente aos meus orientadores e professores por sua orientação constante e especialização. Suas visões e feedback moldaram significativamente a direção desta pesquisa, seus ensinamentos são e serão fundamentais em toda minha carreira e vida.

Em segundo lugar agradeço aos meus queridos colegas de curso que me acompanharam durante toda a minha jornada, em especial agradeço ao João Francisco Londe, Pedro Henrique de Oliveira e Mateus Vieira, não seria possível formar sem vocês. Agradeço também aos meus colegas de escola Luiz Eduardo Senedese, Pedro Costa, Thiago Zambonato e Carlos Carvalho que me acompanham por mais da metade da minha vida, com um apoio infinito e inestimável.

Por fim, mas não menos importante, agradeço a toda a minha família por seu apoio e incentivo incalculáveis. Sua crença em mim tem sido uma força motriz, e sou verdadeiramente grato por sua presença em minha vida.

# Resumo

A Floresta Amazônica, com sua rica biodiversidade e importância global, enfrenta ameaças constantes de desmatamento ilegal. Este estudo busca contribuir para o combate a esse problema utilizando técnicas avançadas de ciência de dados. Através da aplicação de métodos de *machine learning*, exploramos duas abordagens distintas: a segmentação de imagens de satélite usando a arquitetura U-Net e a previsão de desmatamento usando o algoritmo *Random Forest*.

A região do Vale do Javari, com sua densa vegetação e relevância cultural para povos indígenas, serve como cenário para nossa análise. Utilizamos o modelo *Random Forest* para analisar dados físicos relacionados ao desmatamento, como distâncias a hidrovias, rodovias, áreas protegidas e focos de calor. Essa abordagem revela as relações complexas entre variáveis e a ocorrência de desmatamento.

Além disso, empregamos a arquitetura U-Net para segmentar imagens de satélite RGB da região, obtidas por satélites *Sentinel*. Essa técnica avançada nos permitiu entender melhor as características das áreas do Vale do Javari e identificar áreas de interesse para a preservação ambiental.

Os resultados obtidos indicam que ambas as abordagens são promissoras para o combate ao desmatamento. a revisão bibliográfica sobre a efetividade do Plano Amazônia e sua avaliação com o modelo *Random Forest*; e a implementação da U-Net para segmentação semântica de imagens do satélite Sentinel-2 na região do vale do Javari.

Este trabalho contribui para a preservação da Floresta Amazônica e para a compreensão das relações entre fatores físicos e desmatamento. O estudo demonstra o potencial das técnicas de *machine learning* na luta contra ameaças ambientais e destaca a importância da ciência de dados na conservação de ecossistemas valiosos.

# Abstract

The Amazon Rainforest, with its rich biodiversity and global significance, faces constant threats of illegal deforestation. This study aims to contribute to combating this issue using advanced data science techniques. Through the application of machine learning methods, we explore two distinct approaches: satellite image segmentation using the U-Net architecture and deforestation prediction using the Random Forest algorithm.

The Vale do Javari region, with its dense vegetation and cultural relevance to indigenous communities, serves as the backdrop for our analysis. We employ the Random Forest model to analyze physical data related to deforestation, such as distances to waterways, highways, protected areas, and heat spots. This approach reveals the intricate relationships between variables and deforestation occurrence.

Furthermore, we deploy the U-Net architecture to segment RGB satellite images of the region, obtained from Sentinel satellites. This advanced technique allowed us to gain a better understanding of the characteristics of Vale do Javari's areas and identify zones of interest for environmental preservation.

The obtained results indicate that both approaches hold promise for fighting deforestation. A literature review on the effectiveness of the "Plano Amazônia", evaluated using the Random Forest model, and the implementation of U-Net for semantic image segmentation from the satellite Sentinel-2 on the region of Vale do Javari.

This work contributes to the preservation of the Amazon Rainforest and enhances our understanding of the relationships between physical factors and deforestation. The study showcases the potential of machine learning techniques in tackling environmental threats and underscores the importance of data science in conserving valuable ecosystems.

# SUMÁRIO

<b>RESUMO</b> .....	<b>II</b>
<b>ABSTRACT</b> .....	<b>III</b>
<b>1 INTRODUÇÃO</b> .....	<b>1</b>
1.1 MOTIVAÇÃO E OBJETIVO .....	1
<b>2 FUNDAMENTAÇÃO TEÓRICA</b> .....	<b>3</b>
2.1 DADOS GEOGRÁFICOS .....	3
2.1.1 DADOS VETORIAIS .....	3
2.1.2 DADOS RASTER .....	3
2.2 <i>Machine Learning</i> .....	4
2.2.1 <i>Random Forest</i> .....	5
2.2.2 <i>K-fold</i> .....	6
2.2.3 REDES NEURAIS ARTIFICIAIS .....	7
2.2.4 REDES CONVOLUCIONAIS .....	8
<b>3 ESTUDOS RELACIONADOS</b> .....	<b>12</b>
3.1 <i>Science-based planning can support law enforcement actions to curb deforestation in the Brazilian Amazon</i> .....	12
<b>4 DESCRIÇÃO DOS DADOS</b> .....	<b>14</b>
4.1 ESTUDO 1 .....	14
4.1.1 <i>TerraBrasilis</i> .....	14
4.2 ESTUDO 2 .....	15
4.2.1 <i>Sentinel 2</i> .....	15
4.2.2 <i>Mapbiomas</i> .....	16
<b>5 PRÉ-PROCESSAMENTO</b> .....	<b>18</b>
5.1 ESTUDO 1 .....	18
5.2 ESTUDO 2 .....	18
5.2.1 SENTINEL 2 .....	18

5.2.2	MAPBIOMAS .....	18
5.2.3	MONTAGEM DO DATASET.....	19
<b>6</b>	<b>PROCEDIMENTOS E RESULTADOS.....</b>	<b>21</b>
6.1	PROCEDIMENTOS .....	21
6.1.1	ESTUDO 1 .....	22
6.1.2	ESTUDO 2 .....	22
6.2	RESULTADOS .....	23
6.2.1	ESTUDO 1 .....	23
6.2.2	ESTUDO 2 .....	29
<b>7</b>	<b>CONCLUSÃO.....</b>	<b>34</b>
7.1	TRABALHOS FUTUROS .....	35
	<b>BIBLIOGRAFIA.....</b>	<b>36</b>

# LISTA DE FIGURAS

2.1	Ilustração de um algoritmo de Random Forest [Koehrsen ].....	6
2.2	Ilustração de uma ANN com multicamadas de neurônios [LATTARO ].....	7
2.3	Gráfico de uma função sigmoid [Reis ] .....	8
2.4	Ilustração de um modelo de CNN [Demertzis et al. 2023].....	9
2.5	Ilustração do funcionamento de um mecanismo de Max pooling com um filtro de 2x2 [Grecco ].....	9
2.6	Ilustração do funcionamento de uma camada de convolução [Mansano ] .....	10
2.7	Ilustração de um algoritmo de U-NET [Konovalenko et al. 2022] .....	11
5.1	Exemplo de Imagem e Máscara Binária .....	20
6.1	Estrutura do Encoder .....	23
6.2	Estrutura do decoder .....	23
6.3	Classificação de cada polígono da amazônia para o ano de 2019.....	24
6.4	Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2019.....	25
6.5	Classificação de cada polígono da amazônia para o ano de 2020.....	25
6.6	Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2020.....	26
6.7	Classificação de cada polígono da amazônia para o ano de 2021.....	26
6.8	Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2021 .....	27
6.9	Classificação de cada polígono da amazônia para o ano de 2022.....	27
6.10	Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2022.....	28
6.11	Performance da <i>accuracy</i> durante o treinamento do modelo .....	30
6.12	Performance do <i>loss</i> durante o treinamento do modelo .....	30
6.13	Segmentação realizada para imagem com alta presença de rios .....	32
6.14	Segmentação realizada para imagem com alta presença de áreas inundáveis.....	32

# LISTA DE TABELAS

3.1	Área das classes prioritárias definidas pelo estudo citado e pelo “Plano Amazônia 21/22” de 2019 até 2022, além do incremento anual PRODES no desmatamento em cada divisão. ...	13
4.1	Bandas Espectrais Sentinel-2 .....	16
6.1	Área das classes prioritárias definidas pelo algoritmo construído e pelo Plano Amazônia(PA), de 2019 até 2022, além do incremento anual no desmatamento previsto em cada divisão. ....	24
6.2	Erros do modelo construído.....	28
6.3	Contribuição de cada coluna para o modelo construído.....	29
6.4	Resultados de Treino .....	31
6.5	Resultados de validação.....	31
6.6	Resultados de Accuracy e Loss utilizando validação cruzada com 10 folds. ....	33

# 1 | Introdução

## 1.1 Motivação e Objetivo

O Brasil é o país com a maior biodiversidade do mundo, lar de cerca de 100 mil espécies de animais vertebrados e invertebrados[IBAMA ]. Sua riquíssima flora abrange mais de 45 mil espécies de plantas e fungos [BR ] e grande parte dessa rica diversidade é encontrada na maior floresta tropical do planeta Terra, a Floresta Amazônica.

Devido ao seu grande valor, a Floresta Amazônica tem sobre si o constante perigo do desmatamento ilegal, realizado por pessoas gananciosas que visam a se aproveitar de toda a riqueza que a floresta pode oferecer, sem maiores preocupações com as terríveis consequências que tais atividades podem trazer, não só para a Amazônia e o território brasileiro, mas para todo o planeta. Destruir a maior floresta tropical do mundo traz terríveis consequências para o equilíbrio ecológico mundial, resultando em extinção de espécies, alteração de climas e até mesmo o agravamento do aquecimento global[Malhi et al. 2008].

Com o passar dos anos, diversas medidas e planos foram tomados na tentativa de conter esse desmatamento. A exemplo desses, tem-se o Plano Amazônia 21/22, que estabelece diretrizes no combate ao desmatamento. O Plano Amazônia foi criado em maio de 2021 com o intuito de substituir a Operação Verde Brasil 2, antiga operação vigente na amazônia legal, iniciada em maio de 2020.

Em suas diretrizes, o Plano Amazônia define 11 municípios como áreas de risco onde as medidas de combate ao desmatamento serão priorizadas. Conforme o Plano Amazônia, esses municípios contem- plam 70% dos crimes ambientais ocorridos na extensa amazônia legal, que cobre em torno de 60% de todo o território nacional. Também estão descritas nas diretrizes do Plano Amazônia medidas de fortalecimento e integração dos órgãos de fiscalização de combate e desenvolvimento sustentável, com enfoque nos 11 municípios que o plano classifica como prioridade no combate ao desmatamento e crimes ambientais. A meta descrita no Plano Amazônia é de reduzir as taxas de desmatamento na amazônia legal em 8.719 Km<sup>2</sup> até o final de 2022 [PA ].

O Vale do Javari é um território indígena que abrange parte dos territórios dos estados do Amazonas e Acre, com tamanho comparável a Áustria, possuindo 8,5 milhões de hectares. O Vale é uma fronteira natural entre Brasil e Peru e uma fundamental área de proteção ambiental. [Bowman et al. 2021].

O Vale possui a maior concentração de grupos humanos não contatados na Terra, o Vale do ja-

vari é atualmente composto por 9 grupos confirmados e 4 grupos não confirmados de indivíduos não contatados[Tickle 2013] contando com mais de 6000 indivíduos, possuindo uma das maiores concentrações de povos indígenas em isolamento[Silva 2020], entre os povos que habitam a região estão os povos Marubo, Matis, Kanamari, Kulina.

O Vale representa uma importante região para a preservação da biodiversidade brasileira, visto que é encontrada no coração a Floresta Amazônica, além de representar uma importante fortaleza para a cultura indígena brasileira, tendo em vista a quantidade de povos isolados que possuem pouca ou quase nenhuma influência da cultura exterior à região.

Dessa forma, o presente estudo foi cuidadosamente concebido com o propósito central de contribuir de maneira significativa para a mitigação do desmatamento, valendo-se do poder crescente da ciência de dados. Para alcançar essa finalidade, adotamos uma abordagem multifacetada, recorrendo a métodos avançados de machine learning que se mostraram altamente eficazes em suas respectivas aplicações.

Para a análise das imagens de satélite, empregamos com sucesso a arquitetura U-Net, uma técnica amplamente reconhecida e aplicada para segmentação de imagens. Por meio da U-Net, conseguimos uma compreensão mais profunda e abrangente das características das áreas do vale do javari, permitindo uma melhor compreensão da área estudada.

Além disso, para analisar dados físicos relevantes para o contexto de desmatamento, adotamos o método de Random Forest. Esta abordagem demonstrou ser uma ferramenta valiosa para avaliar a relação entre variáveis físicas e ocorrência de desmatamento. A capacidade do Random Forest em lidar com múltiplas variáveis e capturar relações complexas nos dados físicos contribuiu substancialmente para a precisão geral do modelo.

O trabalho é dividido em dois estudos e, assim, no primeiro estudo consta a revisão bibliográfica na seção 3, em que se busca avaliar a efetividade do plano amazônia por meio de um modelo *random forest*2.2.1, utilizando atributos físicos como distância de hidrovias e rodovias, áreas protegidas e focos de calor. O segundo estudo aborda a criação de um modelo *U-NET*, a fim de realizar a segmentação semântica de imagens RGB, advindas de satélites da família Sentinel, da região do Vale do Javari ??, região de alta importância ambiental e social.

O capítulo 2 apresenta a fundamentação teórica do trabalho; o capítulo 3 traz uma breve descrição do estudo e a revisão bibliográfica; o capítulo 4 apresenta a descrição dos dados utilizados e o capítulo 5 apresenta os procedimentos e resultados encontrados. Por fim, o capítulo 7 apresenta as conclusões e trabalhos futuros propostos.

## 2 | Fundamentação teórica

### 2.1 Dados geográficos

#### 2.1.1 Dados Vetoriais

Os dados vetoriais são uma forma comum de representar informações geoespaciais que descrevem características e objetos do mundo real. Eles são amplamente utilizados em SIG (Sistemas de Informação Geográfica) e fornecem uma representação mais detalhada e precisa de elementos geográficos em comparação com dados raster. Os dados vetoriais são compostos por três tipos principais de geometrias: pontos, linhas ou polígonos[Thöny 2017].

Além das geometrias, os dados vetoriais também incluem atributos alfanuméricos que fornecem informações descritivas sobre as entidades representadas. Esses atributos são armazenados em tabelas de atributos associadas aos elementos geométricos e podem incluir dados como nomes, datas, valores e categorias, entre outros[Thöny et al. 2018].

Os dados vetoriais são definidos em um sistema de referência espacial (CRS - Coordinate Reference System), que descreve como as coordenadas espaciais são interpretadas e projetadas em um mapa. O CRS garante que os dados estejam alinhados corretamente e permitam análises espaciais precisas.

Dados vetoriais são amplamente utilizados em várias aplicações, como planejamento urbano, gestão de recursos naturais, mapeamento temático, análise de redes, entre outros. Eles oferecem uma representação flexível e rica em detalhes das características avaliadas.

#### 2.1.2 Dados Raster

Os dados raster são uma forma comum de representar informações geoespaciais que são organizadas em células ou pixels em uma grade regular. Assim como dados vetoriais, dados raster são amplamente utilizados em SIG (Sistemas de Informação Geográfica) e oferecem uma representação eficiente de dados contínuos, como imagens de satélite, modelos digitais de elevação e mapas de temperatura[Adams 1982].

Os dados raster são compostos por uma matriz de células, onde cada célula contém um valor que representa uma medida ou uma característica em um local específico. Esses valores podem ser alturas, intensi-

dades de refletância, valores de temperatura, classificações de uso do solo, entre outros.

Uma das características dos dados raster é que eles possuem uma resolução espacial, que determina o tamanho de cada célula na grade. Quanto menor a resolução, maior é o nível de detalhe e a quantidade de dados necessária para armazenar a informação. Por exemplo, uma imagem de satélite com uma resolução de 10 metros significa que cada célula representa uma área de 10 metros por 10 metros.

Além da resolução espacial, os dados raster também podem ter uma resolução espectral, que se refere ao número de bandas espectrais utilizadas para capturar informações em diferentes comprimentos de onda. Por exemplo, uma imagem de satélite multiespectral pode ter várias bandas, como infravermelho próximo, vermelho e azul, que capturam informações sobre a vegetação, a presença de água e a intensidade da refletância[Danehpash 2015].

Assim como os dados vetoriais, dados raster também utilizam o sistema de coordenadas de referência espacial (CRS - Coordinate Reference System). O CRS define a projeção cartográfica e o sistema de coordenadas utilizado para posicionar os dados raster em um espaço geográfico.

Os dados raster oferecem várias vantagens, incluindo a capacidade de armazenar grandes quantidades de informações geoespaciais, a flexibilidade para representar dados contínuos e a facilidade de aplicar operações matemáticas e análises espaciais. Eles são amplamente utilizados em diferentes áreas, como monitoramento ambiental, análise de cobertura do solo, modelagem hidrológica, entre outros.

## 2.2 *Machine Learning*

Com o passar dos anos e o rápido avanço da computação e da tecnologia da informação, o mundo dos dados tem ganhado cada vez mais força, sendo atualmente peça vital em qualquer uma das grandes empresas e conglomerados. Assim, diversas técnicas foram desenvolvidas para melhorar a interpretação desses dados, possibilitando a obtenção de conclusões melhores e mais acuradas.

*Machine Learning*, ou aprendizado de máquina, é uma técnica utilizada na área da ciência de dados, um subcampo da inteligência artificial, que busca emular a maneira que seres humanos aprendem, buscando padrões e *insights* em grandes bancos de dados, a fim de produzir cada vez melhores classificações e previsões para uma melhor tomada de decisão acerca dos projetos onde essas técnicas são aplicadas[Cioffi et al. 2020].

Algumas das técnicas englobadas nesse ramo são diversos tipos de regressões, algoritmos que buscam semelhanças entre grupos de dados, como o algoritmo de *clustering*, e até algoritmos de tomada de decisão como árvores de decisão[Dietterich 2000]. Entre as atuais aplicações de *machine learning*, estão sistemas de recomendações e de anúncios utilizados na internet, detecção de fraudes e classificação de imagens, entre outros.

### 2.2.1 *Random Forest*

No contexto do aprendizado de máquina, um dos algoritmos amplamente empregados é o "Random Forest". Este modelo se destaca por sua habilidade em efetuar previsões por meio da criação de múltiplas árvores de decisão aleatórias. A técnica visa alcançar uma predição mais precisa ao utilizar um mecanismo de votação majoritária [Breiman 2001].

Um componente fundamental na aplicação da técnica "Random Forest" é a árvore de decisão. Esta estrutura é um instrumento visual que esquematiza as distintas trajetórias resultantes de uma série de escolhas interconectadas. Tal método possibilita a comparação de variados cursos de ação com base em seus respectivos custos, probabilidades e benefícios, o que pode ser aplicado tanto em interações informais como na formulação de algoritmos matemáticos para previsões otimizadas.

A estrutura de uma árvore de decisão é iniciada por um nó único que se desdobra em múltiplas opções de desfechos. Cada uma dessas opções se desdobra novamente em outros nós, criando assim uma ramificação similar à de uma árvore. Esse padrão visual permite a delimitação clara de diversas possibilidades resultantes. Cada tomada de decisão ao longo da árvore conduz a um estágio mais próximo da previsão ou regressão almejada [Dietterich 2000]. Entretanto, esse método pode ser suscetível a problemas como viés sistemático (*bias*) e ajuste excessivo (*overfitting*) [Ying 2019], nos quais o modelo pode se adaptar excessivamente a um conjunto de dados específico.

No entanto, tais desafios são atenuados pelo algoritmo "Random Forest", que adota um enfoque diversificado. O método emprega múltiplas árvores de decisão para abordar um mesmo problema, permitindo assim distintas conclusões e decisões referentes a um mesmo conjunto de dados. A decisão final é então determinada pela maioria das escolhas individuais das árvores (voto majoritário), efetuada ao término de cada previsão realizada por cada árvore.

Dessa forma, o "Random Forest" busca superar as limitações das árvores de decisão individuais, explorando a diversidade das previsões geradas por múltiplas árvores para alcançar um resultado final mais robusto e preciso. Na imagem 2.1 está exemplificado um algoritmo de random forest

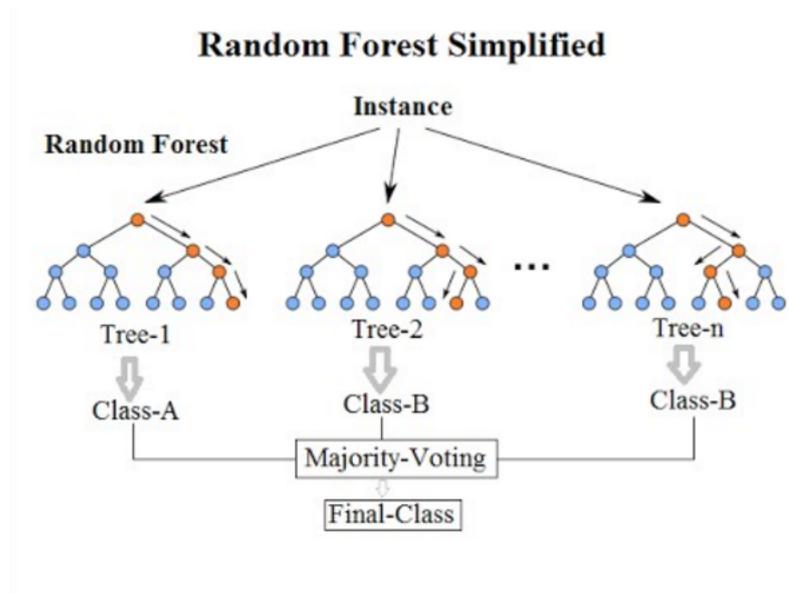


Figura 2.1: Ilustração de um algoritmo de Random Forest [Koehrsen ]

### 2.2.2 *K-fold*

O *K-fold* é uma ferramenta valiosa no campo da avaliação de modelos de aprendizado de máquina, proporcionando uma estimativa mais robusta do desempenho de um modelo em relação aos dados disponíveis. Essa técnica envolve a divisão do conjunto de dados original em  $k$  partes, também conhecidas como *folds*, com aproximadamente o mesmo tamanho. O objetivo é treinar e avaliar o modelo  $k$  vezes, em que, a cada iteração, um *fold* diferente é utilizado como conjunto de teste, enquanto os  $k-1$  *folds* restantes são empregados como conjunto de treinamento.

O conjunto de teste, se refere a uma porção dos dados que não é utilizada durante a fase de treinamento do modelo. Em vez disso, o conjunto de teste é reservado para avaliar a capacidade de generalização do modelo para novos dados, ou seja, dados que não foram utilizados para treiná-lo. A avaliação no conjunto de teste fornece uma medida do desempenho real do modelo em situações do mundo real, permitindo a identificação de eventuais problemas de overfitting, em que o modelo se ajusta excessivamente aos dados de treinamento, prejudicando sua capacidade de generalização.

A utilização do *K-fold* permite uma avaliação mais completa e confiável do desempenho do modelo, uma vez que cada observação é utilizada tanto para treinamento quanto para teste. Isso reduz o impacto da aleatoriedade na seleção dos conjuntos de treinamento e teste, fornecendo uma estimativa mais estável das métricas de avaliação, como precisão, acurácia e erro. Além disso, a técnica permite detectar padrões de desempenho que podem variar dependendo da composição dos conjuntos de treinamento e teste.

## 2.2.3 Redes Neurais Artificiais

Redes neurais artificiais ou *Artificial neural networks (ANN)* são um modelo modelo de *machine learning* que busca simular o funcionamento de redes neurais biológicas, utilizando a interconexão de estruturadas chamadas de neurônios em camadas, em que tal modelo é capaz de aprender relações complexas e padrões entres os dados de entrada[Zou et al. 2009].Na figura 2.2 [e exemplificada uma Ann

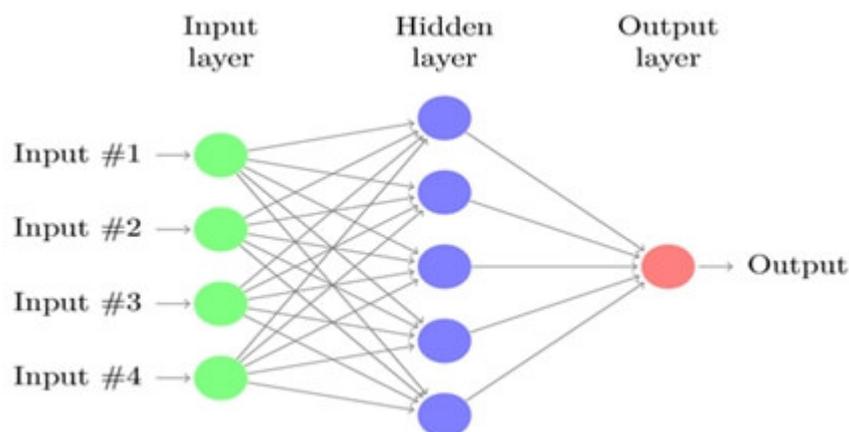


Figura 2.2: Ilustração de uma ANN com multicamadas de neurônios [LATTARO ]

O neurônio ou perceptron é uma função matemática que recebe um conjunto de entradas ponderadas por meio de pesos e *bias*, que é uma tendência que permite deslocar a função de ativação adicionando uma constante à entrada. O neurônio aplica uma função de ativação para produzir uma saída e a encaminha para a próxima camada. A função de ativação introduz não-linearidade no modelo, permitindo capturar relações complexas entre as entradas e saídas. A equação de um neurônio pode ser visualizada na equação 2.1, onde  $y$  representa a saída do neurônio,  $\phi$  representa a função de ativação,  $x_i$  representa a entrada do neurônio,  $w_{ki}$  representa os pesos associados a cada neurônio e  $b$  o *bias* associado a cada neurônio[Gallant et al. 1990]. .

$$y = \phi \left( \sum_{i=1}^m x_i w_{ki} + b \right) \quad (2.1)$$

### 2.2.3.1 Função Sigmoid

Como principal componente por trás da não linearidade das ANNs tem-se a função de ativação. Uma das principais funções de ativação utilizadas é a função *Sigmoid*.

A função *Sigmoid*, também conhecida como função logística, é uma função de ativação que mapeia um valor de entrada para os valores entre 0 e 1, sendo assim uma ótima função de ativação para classificações binárias[Han and Moraga 1995]. Sua fórmula está representada na função 2.2 e sua representação gráfica está representada na figura 2.3.

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.2)$$

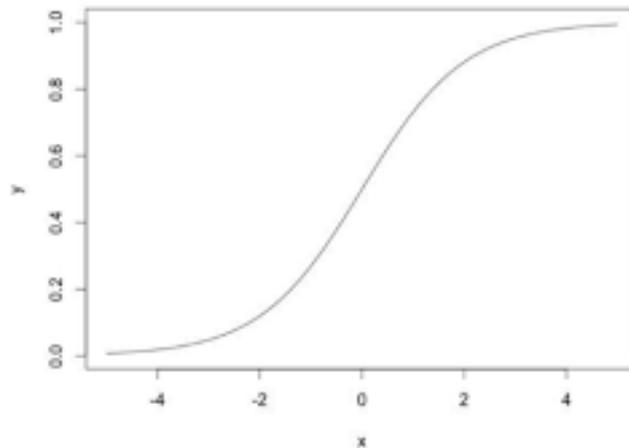


Figura 2.3: Gráfico de uma função sigmoide [Reis ]

## 2.2.4 Redes Convolucionais

Redes convolucionais, também conhecidas como *Convolutional Neural Networks (CNNs)*, representam um tipo especializado de arquitetura de rede neural projetado especialmente para lidar com dados de grade, como imagens. Sua principal finalidade é realizar o processamento de imagens, permitindo a detecção e classificação de padrões complexos e características visuais presentes nas imagens. Isso as torna altamente eficazes em tarefas de visão computacional, como reconhecimento de objetos, segmentação de imagens e análise de imagens médicas.

A peça central que define as redes convolucionais é a camada de convolução. Essa camada utiliza filtros (ou kernels) para realizar a operação de convolução nas imagens de entrada. Essa operação envolve a sobreposição do filtro em várias posições da imagem e a multiplicação dos valores do filtro pelos valores dos pixels correspondentes da imagem. O resultado dessa operação é chamado de "feature map" ou mapa de características, que destaca padrões e características específicas da imagem, como bordas, texturas e formas.

Além das camadas de convolução, as redes convolucionais frequentemente empregam camadas de *pooling*, como a camada de *max pooling*, que reduzem a dimensionalidade dos mapas de características, mantendo as informações mais relevantes e reduzindo a quantidade de parâmetros da rede. Isso ajuda a tornar a rede mais eficiente em termos computacionais.

As camadas de convolução e *pooling* são normalmente seguidas por uma ou mais camadas totalmente conectadas, que atuam como classificadores finais. Essas camadas agregam as informações extraídas das camadas anteriores e fazem a previsão da classe ou categoria à qual a imagem pertence.

A combinação de camadas de convolução, camadas de *pooling* e camadas totalmente conectadas permite que as redes convolucionais aprendam automaticamente características complexas e hierárquicas das imagens, o que as torna muito eficazes em tarefas de classificação e segmentação de imagens. Essa capacidade de extração de características e aprendizado de padrões é ilustrada na Figura 2.4, que demonstra a evolução das características ao longo das camadas de uma rede convolucional.

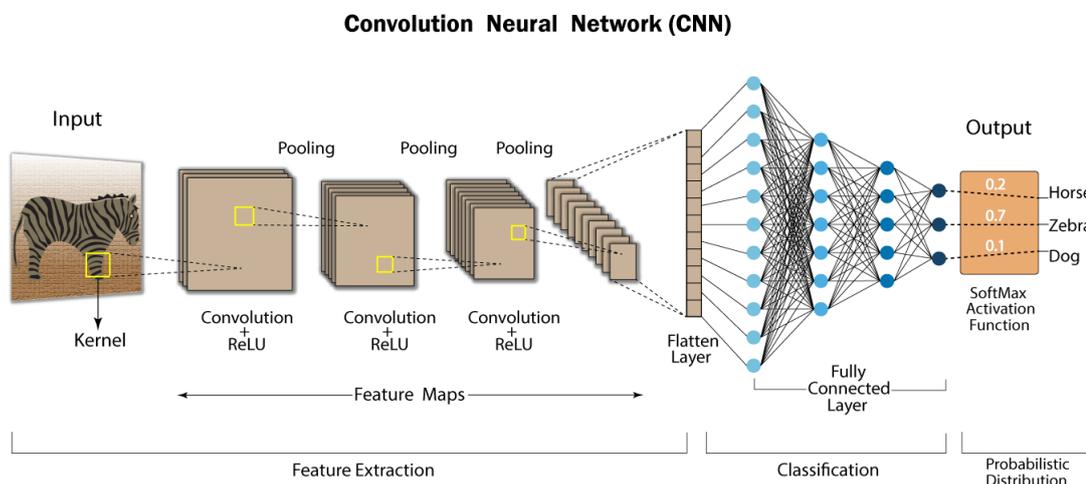


Figura 2.4: Ilustração de um modelo de CNN [Demertzis et al. 2023]

### 2.2.4.1 Max pooling

A camada de *pooling* é responsável por reduzir a dimensionalidade espacial de cada imagem, a fim de reduzir o número de parâmetros e consequentemente reduzir o custo computacional do modelo [O’Shea and Nash 2015]. O método mais comumente utilizado para a redução da dimensionalidade é o *Max pooling*, método que consiste em utilizar o valor máximo encontrado em um filtro de dimensões  $N \times N$ , reduzindo as dimensões da imagem original. Na imagem 2.5 está ilustrado o funcionamento de uma camada de máx pooling.

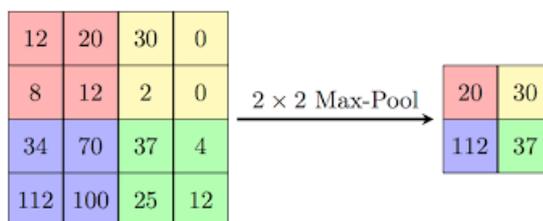


Figura 2.5: Ilustração do funcionamento de um mecanismo de Max pooling com um filtro de 2x2 [Grecco ]

### 2.2.4.2 Camadas de Convolução

Camadas de convolução são o principal componente das CNNs, elas são definidas por um conjunto de filtros lineares que percorrem a imagem de entrada para realizar a convolução. Cada filtro é composto por uma "janela" que desliza pela imagem, realizando multiplicações elementares dos valores de cada pixel por um conjunto de pesos a fim de ressaltar informações importantes da imagem, gerando matrizes chamadas de mapas de características. O conjunto de tais matrizes representa a saída da camada.[Liu et al. 2015].

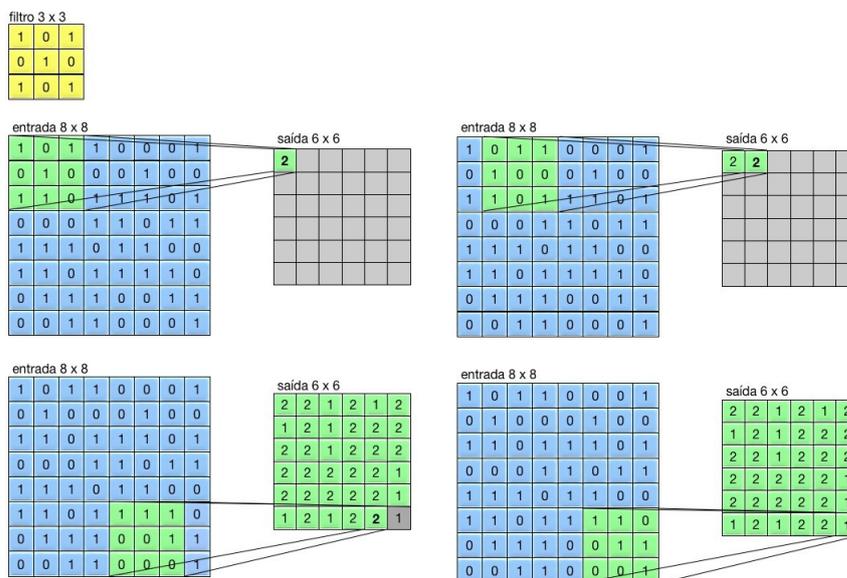


Figura 2.6: Ilustração do funcionamento de uma camada de convolução [Mansano ]

### 2.2.4.3 Stride

O passo (*stride*) em uma camada de convolução é um parâmetro que define o deslocamento da janela de convolução enquanto percorre a imagem de entrada. Ele determina o número de pixels que a janela se move horizontalmente e verticalmente a cada iteração. Quando o passo é igual a 1, a janela de convolução se move um pixel de cada vez, resultando em uma sobreposição considerável entre as regiões de convolução adjacentes; assim, a altura e largura da camada de saída serão iguais às da camada de entrada. No entanto, quando o passo é maior que 1, ocorre uma redução na quantidade de sobreposição entre as janelas de convolução, resultando em uma camada de saída com dimensões espaciais menores[O'Shea and Nash 2015].

### 2.2.4.4 U-NET

A U-NET é um modelo de rede completamente convolucional, proposta primeiramente para um desafio de segmentação precisa de estruturas em imagens Biomédicas, como órgãos ou lesões [Du et al. 2020]. Sua arquitetura é única, composta por um *encoder* e um *decoder*, conhecidos como caminhos da contração e expansão, projetados com o objetivo da segmentação semântica ou classificação por pixel.

O caminho da contração (*Encoder*) é responsável por extrair informações de alto nível da imagem de entrada, reduzindo gradualmente a resolução espacial por meio de camadas de convolução e operações de *pooling*.

O Caminho da expansão (*Decoder*) é responsável por reconstruir a imagem gerada pelo encoder, por meio de camadas de convolução transpostas (*upsampling*), relacionando informações de alto nível com informações de baixo nível por meio de conexões *skip* (pulos), auxiliando na preservação de detalhes finos e na recuperação de informações perdidas nas etapas de contração[John and Zhang 2022]. A arquitetura de um modelo U-NET está representada na imagem 2.7.

Sua estrutura é altamente eficiente na classificação pixel a pixel de imagens, classificando cada pixel em classes, por isso tem sido amplamente empregada em diversas áreas como segmentação de edifícios em imagens de satélite, segmentação de estruturas em imagens de sensoriamento remoto e análise de dados geoespaciais, entre outras aplicações.

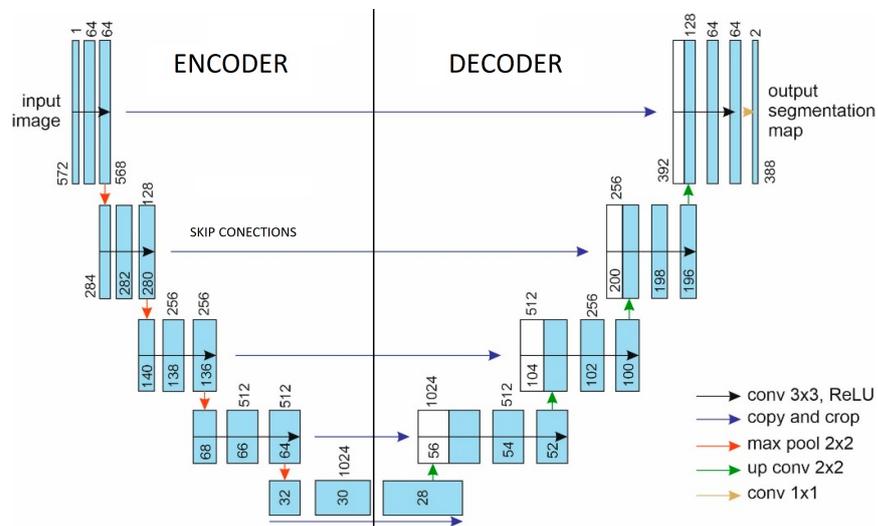


Figura 2.7: Ilustração de um algoritmo de U-NET [Konovalenko et al. 2022]

## 3 | Estudos relacionados

### 3.1 *Science-based planning can support law enforcement actions to curb deforestation in the Brazilian Amazon*

(Planejamento baseado em ciência pode apoiar ações de aplicação da lei para conter o desmatamento na Amazônia brasileira)

O Estudo "*Science-based planning can support law enforcement actions to curb deforestation in the Brazilian Amazon*" [Mataveli et al. 2022] busca, por meio de técnicas de *machine learning*, mais especificamente a técnica de *Random Forest*, uma maneira mais eficiente de combate ao desmatamento na Amazônia em comparação com as diretrizes do Plano Amazônia.

Em 2021, os municípios abrangidos pelo Plano Amazônia eram responsáveis por somente 37% do aumento no desmatamento na Amazônia legal, o que se mostra pouco para o que deveria ser o principal plano de combate ao seu desmatamento, sendo insuficiente para atingir a meta de redução do Plano. Por mais que tais municípios possuam altas taxas de desmatamento e seus monitoramentos sejam essenciais para o controle do desmatamento no Brasil, a exclusão ou falta de prioridade para outras áreas com uma maior concentração de desmatamento pode se mostrar fatal na luta pela sobrevivência que a Floresta Amazônica enfrenta nos dias de hoje. Assim, esse estudo busca mostrar uma melhor divisão das terras da Amazônia legal a fim de identificar os maiores incrementos no desmatamento ocorrido em menores porções de terra.

O estudo utiliza dados obtidos do site TerraBrasilis 4.1.1. Os autores organizaram os dados de maneira a criar um dataset (conjunto de dados) para cada um dos 4 anos, de 2019 até 2022, dividindo a Amazônia em 6.783 polígonos com áreas iguais, o dataset está descrito na seção 4

Utilizando o algoritmo de regressão com multivariáveis no modelo *Random Forest*, os autores conseguiram prever o risco de desmatamento em cada área para o ano seguinte, dividindo o dataset em três classificações com base em seu risco de desmatamento. Acima do 90 percentil, foram classificados como alto risco; entre 90 e 70 percentil, foram classificados como médio risco e, abaixo do 70 percentil, classificados como baixo risco. Os resultados do estudo estão expostos na tabela 3.1, assim como os dados expostos nas diretrizes do Plano Amazônia.

		Alto	Médio	Baixo	Plano Amazônia
2019	Área total (Km2)	422,727	847,315	2,991,068	574,724
	Incremento no desmatamento PRODES (Km2)	7261	2929	707	3443
	Incremento Anual no desmatamento (%)	67	27	6	32
2020	Área total (Km2)	423,150	847,118	2,990,841	574,724
	Incremento no desmatamento PRODES (Km2)	6882	2540	1079	3908
	Incremento Anual no desmatamento (%)	66	24	10	37
2021	Área total (Km2)	414,603	850,154	2,996,351	574,724
	Incremento no desmatamento PRODES (Km2)	7152	3047	654	4048
	Incremento Anual no desmatamento (%)	66	28	6	37
2022	Área total (Km2)	414,603	848,896	2,997,610	574,724
	Incremento no desmatamento PRODES (Km2)	-	-	-	-
	Incremento Anual no desmatamento (%)	-	-	-	-

Tabela 3.1: Área das classes prioritárias definidas pelo estudo citado e pelo “Plano Amazônia 21/22” de 2019 até 2022, além do incremento anual PRODES no desmatamento em cada divisão.

Assim, olhando as áreas classificadas como alto risco, percebe-se que o algoritmo elaborado conseguiu agrupar um número de quase duas vezes mais incremento no desmatamento em uma área menor, com quase 100 mil  $km^2$  a menos, se comparado com a área coberta pelo Plano Amazônia 21/22. Dessa forma, o estudo evidenciou a ineficiência da divisão observada no Plano Amazônia e que é possível priorizar outras áreas com maior risco de desmatamento.

## 4 | Descrição dos Dados

### 4.1 Estudo 1

#### 4.1.1 *TerraBrasilis*

Os dados utilizados neste documento, e no estudo relacionado<sup>3</sup>, são retirados do site TerraBrasilis [TerraBrasilis ], plataforma desenvolvida pelo Instituto Nacional de Pesquisas Espaciais (INPE) para a divulgação e estudo de dados acerca dos biomas brasileiros, gerados por programas de monitoramento do governo brasileiro, como o PRODES e o DETER. Na plataforma, estão dispostos diversos dados a respeito de todos os biomas brasileiros, dados sobre desmatamento, focos de calor, hidrografia, terras indígenas e até mesmo áreas sem vegetação.

Diversos conjuntos de dados (*datasets*) estão disponíveis no TerraBrasilis datasets a respeito da Hidrografia, incremento do desmatamento e focos de calor. Utilizando-se de tais Datasets, os autores do estudo descrito em 3 montaram o *dataset* utilizado neste estudo. As colunas do dataset estão descritas a seguir.

- Desmatamento no ano anterior(km<sup>2</sup>).
- Desmatamento acumulado nos 2 anos anteriores(km<sup>2</sup>).
- Desmatamento acumulado nos 4 anos anteriores(km<sup>2</sup>).
- Distância de rodovias(km).
- Distância de hidrovias(km).
- Distância a ponto de grade > 1% de desmatamento no ano anterior (km).
- Distância a ponto de grade > 2% de desmatamento no ano anterior (km).
- Focos de calor.
- Área Protegida(km<sup>2</sup>).
- Incremento no desmatamento detectado naquele ano(Km<sup>2</sup>).

Para a inserção no modelo de Random Forest, foi utilizada como *ground truth* (verdade absoluta) a variável de incremento no desmatamento detectado em cada ano, sendo como objetivo do estudo treinar o modelo para prever o incremento no desmatamento em anos posteriores.

## 4.2 Estudo 2

Todas as imagens foram adquiridas utilizando a plataforma do Earth Engine, plataforma desenvolvida pela Google, de processamento e análise de dados geoespaciais em larga escala, disponibilizando um acesso a uma larga escala de dados e ferramentas de processamento. Dentro de tal plataforma, diversos grupos de dados são disponibilizados, dados de satélites como os satélites da família Sentinel 4.2.1, dados climáticos, geográficos, fluviais e florestais.

Com a larga escala de ferramentas para análises geoespaciais disponibilizadas, a plataforma pode desempenhar funções importantíssimas, auxiliando em diferentes áreas de estudo, como desmatamento, avaliação de recursos hídricos, análise de mudanças do uso do solo, detecção de incêndios florestais, previsão de colheitas, entre outras. As imagens, tanto do Sentinel-2 quanto do MapBiomas, foram baixadas utilizando uma query (procedimento de consulta) em JavaScript disponibilizada na própria plataforma.

### 4.2.1 *Sentinel 2*

O Sentinel-2 é uma missão da família Sentinel, com sensores multi espectrais, desenvolvida pela Agência Espacial europeia, e seu principal objetivo é promover dados de alta resolução para monitoramento da cobertura terrestre, mudanças climáticas e monitoramento de desastres.[Phiri et al. 2020]. A missão Sentinel-2 é composta por dois satélites: Sentinel-2A e Sentinel-2B.

A resolução espacial dos satélites da família Sentinel variam entre 10m e 60m a depender da banda espectral, operando desde o espectro visíveis até o infravermelho próximo, capturando dados em 13 bandas espectrais. Os satélites cobrem todo o globo com um tempo de revisita variando em cada região. Para o Vale do Javari esse tempo é de 14 ou 15 dias.[Segarra et al. 2020]. As bandas do Sentinel-2 estão descritas na tabela 4.1.

Tabela 4.1: Bandas Espectrais Sentinel-2

<b>Band</b>	<b>Resolution (m)</b>	<b>Central Wavelength (nm)</b>	<b>Bandwidth (nm)</b>
Coastal Aerosol (B1)	60	443	20
Blue (B2)	10	490	65
Green (B3)	10	560	35
Red (B4)	10	665	30
Red-Edge (B5)	20	705	15
Red-Edge (B6)	20	740	15
Red-Edge (B7)	20	783	20
NIR (B8)	10	842	115
Vegetation RE (B8A)	20	865	20
Water Vapor (B9)	60	945	20
SWIR Cirrus (B10)	60	1375	30
SWIR (B11)	20	1610	90
SWIR (B12)	20	2190	180

Para este estudo, foram adquiridas ao todo 356 imagens referentes à região do Vale do Javari ???. As imagens são referentes aos anos de 2018 a 2020. Foram utilizadas as bandas B2, B3 e B4 a fim de se construir uma imagem RGB da terra do Vale do Javari.

#### 4.2.2 *Mapbiomas*

O projeto de Mapeamento Anual do Uso e Cobertura da Terra no Brasil, o MapBiomas, foi fundado em 2015 por uma colaboração entre ONGs, universidades e *startups* de tecnologia. O projeto consiste em um mapeamento anual das terras e corpos de água do Brasil, utilizando-se de dados a partir de 1985, fornecendo informações detalhadas e precisas sobre a vegetação, florestas, agricultura, corpos d'água e outros recursos naturais e construídos do país.

Os dados gerados pelo projeto MapBiomas têm sido fundamentais para uma variedade de aplicações, incluindo monitoramento ambiental, planejamento de conservação, desenvolvimento de políticas e gestão sustentável do uso da terra. Eles têm contribuído para uma melhor compreensão dos padrões de desmatamento, expansão agrícola, crescimento urbano e outras mudanças significativas no uso da terra no Brasil [Neves et al. 2017].

Foram utilizados dados advindos da coleção 3.0 do Mapbiomas que possuem uma resolução espacial de 30m. O projeto utiliza uma combinação de algoritmos de aprendizado de máquina e técnicas de classificação de imagem para processar e analisar grandes volumes de imagens de satélite de todo o território brasileiro, classificando-o em 33 classes com mais de 80% de precisão[Fendrich et al. 2020]. Sua resolução espacial e detalhamento está entre a melhores se comparado com a maioria dos *datasets* disponíveis atualmente[Pérez-Hoyos et al. 2017] , mostrando-se fonte confiável para estudos de desmatamento na Amazônia.

Foram adquiridos dados a respeito da região do Vale do Javari ?? , dos anos de 2018 até 2020. Estão

presentes 6 classes na região, sendo elas:

- Forest Formation - formações florestais, representando cerca de 99,29% do território.
- Areas Naturales Inundables - áreas naturais inundáveis, representando cerca de 0.000003% do território.
- Wetland - campo alagado e área pantanosa, representando cerca de 0,01% do território.
- Grassland - formação campestre, representando cerca de 0,12% do território.
- Farming - agropecuária, representando cerca de 0,05% do território.
- River - formação fluvial, representando cerca de 0,001% do território.
- Non Observed - não observado, representando cerca de 0,52% do território.

## 5 | Pré-processamento

### 5.1 Estudo 1

Com o objetivo de explorar mais a fundo o modelo proposto pelo estudo descrito(4), foi utilizado o dataset referenciado anteriormente, montado e disponibilizado pelos autores do estudo. Para seguir os precedimentos do estudo, foram escolhidos os datasets referentes aos anos de 2019 e 2020 para treinar o modelo, visto que os anos de 2021 e 2022 não possuíam os dados a respeito do incremento do desmatamento disponibilizados. Os datasets foram concatenados e separados em datasets de treino e teste.

### 5.2 Estudo 2

#### 5.2.1 Sentinel 2

Devido à grande quantidade utilizada de imagens geradas pelo Sentinel 2, sua resolução de 10m/pixel e CRS EPSG:32718 foi escolhida como padrão para o estudo, a fim de otimizar o processamento das imagens. As imagens foram separadas em arquivos menores de 512x512 pixels com o objetivo de possibilitar o processamento mais rápido das imagens.

Tal processamento gera alguns problemas como possíveis informações incompletas nas bordas, alto número de bordas e possível perda de contexto global. Assim, para o treinamento do modelo, foram selecionadas somente as imagens em que 99% de seus pixels não representassem valores de 0 ou 255, com o objetivo de usar as imagens com maior quantidade de informação possível, resultando em 14.000 imagens, todas as imagens retiveram suas informações de contexto global.

#### 5.2.2 MapBiomias

Os dados raster2.1 adquiridos do Mapbiomas possuem uma resolução espacial de 30m/pixel e um CRS do modelo: EPSG:4326. Para que os dados do Mapbiomas possam ser utilizados em conjunto com os dados do Sentinel, é preciso modificá-los para atingir uma mesma resolução espacial e o mesmo CRS. Assim, o CRS foi alterado para EPSG:32718.

Como as imagens do Sentinel-2 possuem uma resolução de 10m/pixel, e as imagens do Mapbiomas possuem uma resolução de 30m/pixel, foi utilizado o método de interpolação pelo vizinho mais próximo. O valor de um pixel P em uma imagem ampliada é igual ao valor do pixel mais próximo da posição de P na imagem original [Han 1303]. Assim, a imagem original do Mapbiomas foi convertida para uma imagem com 10m/pixel de resolução espacial.

Da mesma forma, para facilitar o processamento posterior dos dados, cada imagem também foi separada em arquivos menores de 512x512 pixels. Somente foram consideradas para o treinamento do modelo imagens onde 99% de seus pixels não representassem valores de 0 ou 255, de maneira a serem utilizadas as imagens com maior quantidade de informação possível, resultando em 3.100 imagens.

### 5.2.3 Montagem do Dataset

Para a criação de um dataset para a segmentação semântica no Vale do Javari, a junção das imagens do Sentinel-2 e MapBiomas se mostra como muito oportuna, visto que as imagens do Sentinel-2 fornecem dados detalhados sobre a cobertura e uso da terra, permitindo identificar diferentes tipos de vegetação, áreas urbanas, corpos d'água, entre outros, enquanto os dados do Mapbiomas fornecem uma classificação consistente e atualizada da cobertura da terra em uma escala mais ampla. A junção dessas informações permite uma análise mais abrangente e integrada da cobertura e uso da terra.

Das 14.000 imagens do Sentinel-2 restantes, foram selecionadas as imagens que possuíssem intersecção com alguma das imagens do Mapbiomas, com o fim de acelerar o processamento das imagens, assim restaram 3.835 imagens do Sentinel-2.

Considerando a grande frequência de pixels da classe de *Forest Formation*, (em torno de 99% 4.2.2), foi encontrada uma baixíssima frequência de pixels de outras classes. Assim, para evitar problemas de *overfitting* (sobreajuste) [Ying 2019], procurou-se todo par de imagens entre as imagens do Sentinel-2 e as imagens do Mapbiomas que resultassem em imagens com pelo menos alguma classe diferente da classe *Forest Formation*, com o objetivo de agregar o máximo de informações possíveis acerca das classes com baixa frequência. Dessa forma, 2.109 pares foram formados.

De maneira a preparar as imagens para a inserção no modelo de U-NET, foi feita junção de cada par de imagem, gerando uma imagem RGB e uma máscara binária para a região de intersecção entre as imagens. Na máscara binária, que representa o ground truth (verdade fundamental), cada pixel da classe de floresta assumiu o valor 1, enquanto todos os pixels de outras classes foram classificados como 0. Um exemplo de uma imagem gerada está representada na figura 5.1.

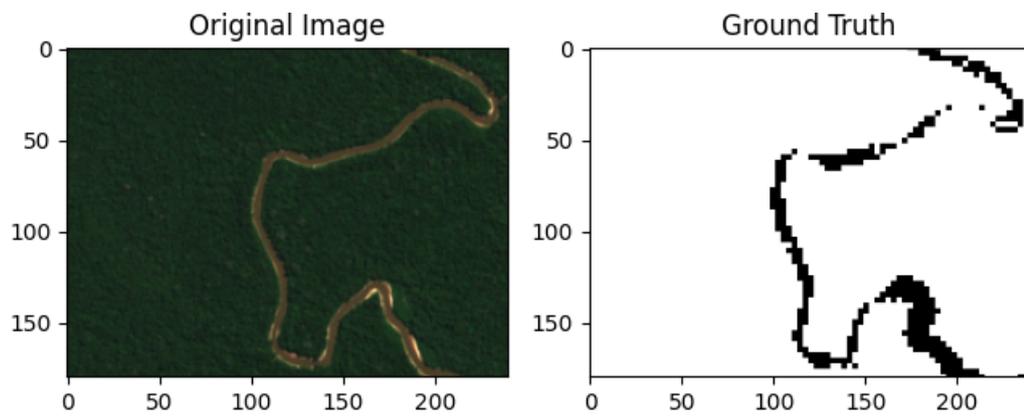


Figura 5.1: Exemplo de Imagem e Máscara Binária

Foram separadas as 2.109 imagens do dataset em um dataset de treino, contendo 1.692 imagens, um dataset de teste, contendo 187 imagens, e um dataset de validação, contendo 230 imagens.

# 6 | Procedimentos e Resultados

## 6.1 Procedimentos

Todos os códigos utilizados para ambos os estudos foram desenvolvidos utilizando a linguagem de programação Python, em sua versão 3.9.12. Python é uma linguagem de programação orientada ao objeto de alto nível, cuja utilização vem crescendo muito recentemente devido a sua simples sintaxe, com uso cada vez maior em projetos nas áreas da ciência de dados e *machine learning*, desenvolvimento web, cálculos científicos e desenvolvimento de softwares. Para o desenvolvimento, foi escolhido o editor de texto *Vs code* devido à familiaridade com a ferramenta, fácil visualização e sua ótima ferramenta de depuração.

Outra vantagem para a utilização do Python é a diversidade de bibliotecas disponíveis, que habilitam várias funções para as mais diversas aplicações. Para os códigos elaborados, diversas bibliotecas foram utilizadas no decorrer deste desenvolvimento. As principais bibliotecas utilizadas foram Numpy, Pandas, Geopandas, Scikit-learn (Sklearn), Keras, Rasterio e Matplotlib.

A biblioteca Numpy (*Numerical Python*) se configura como uma das bibliotecas mais utilizadas para diversas aplicações em Python. É uma biblioteca voltada para computação numérica, fornecendo estruturas de dados e funções de alto desempenho para trabalhar com *arrays* (vetores) multidimensionais e realizar cálculos numéricos complexos. Os arrays do NumPy, chamados *ndarray*, mostram-se mais eficientes que as listas tradicionais do Python, pois permitem o armazenamento e manipulação eficiente de grandes quantidades de dados numéricos, além de serem otimizados para realizar operações matemáticas em larga escala de forma rápida e eficiente.

As bibliotecas Pandas e Geopandas são essenciais para a manipulação e análise de dados tabulares e geoespaciais, respectivamente. Pandas é uma biblioteca que fornece estruturas de dados de alto desempenho e ferramentas de análise de dados tabulares para Python. O principal objeto de dados em Pandas é o *DataFrame*, que é uma estrutura bidimensional que organiza os dados em colunas nomeadas. Os *DataFrames* fornecem uma maneira eficiente de manipular e analisar grandes volumes de dados, facilitando tarefas como filtragem, transformação e visualização. GeoPandas é uma extensão da biblioteca Pandas que adiciona suporte para dados geoespaciais, combinando a facilidade para manipulação de dados do Pandas com funcionalidades geoespaciais de pacotes como GEOS e do Shapely. O principal objeto de dados da biblioteca GeoPandas é o *GeoDataFrame*, que é uma extensão do *DataFrame* do Pandas com uma coluna adicional chamada "*geometry*". Essa coluna permite armazenar e manipular objetos geométricos como

pontos, linhas e polígonos, armazenando suas formas e coordenadas.

As bibliotecas Sklearn e Keras são utilizadas para tarefas de aprendizado de máquina e mineração de dados em Python. Keras é uma biblioteca para construção e treinamento de redes neurais. Ela foi projetada para ser simples, modular e extensível, permitindo que os usuários desenvolvam modelos de aprendizado profundo de forma rápida e fácil. Sklearn ou Scikit-learn é uma biblioteca de aprendizado de máquina que fornece uma ampla variedade de algoritmos de aprendizado supervisionado e não supervisionado, como o *Random Forest*. Assim como a Keras, é projetada para ser simples e eficiente, oferecendo uma ampla gama de ferramentas para análise e modelagem de dados.

A biblioteca Rasterio é utilizada para ler, escrever e manipular dados raster geoespaciais. Ela oferece uma maneira poderosa e eficiente de trabalhar com conjuntos de dados raster, permitindo que os usuários realizem várias operações nos dados, como leitura de valores de pixels, recorte, reprojeção e salvamento dos dados em diferentes formatos.

Por último, temos a biblioteca Matplotlib, uma das bibliotecas de visualização de dados mais populares em Python. Ela oferece uma ampla variedade de funções para a criação de gráficos estáticos, gráficos 2D e 3D, além de ser altamente personalizável. O Matplotlib tem integração direta com o Geopandas, o que permite a visualização de dados geoespaciais de forma eficiente e conveniente.

### 6.1.1 Estudo 1

Foi construído um modelo de regressão do tipo *Random forest*, utilizando-se a biblioteca Sklearn, tendo por fim prever o incremento no desmatamento de cada polígono daquele ano com base no atributos descritos (4). O modelo foi treinado com o geodataset de treino construído, utilizado para prever o desmatamento de cada um dos polígonos que compõem a amazônia legal. O resultado do modelo foi atribuído à coluna "Desmatamento previsto" e exposto junto ao restante do geodataset.

Assim, a mesma divisão realizada no estudo descrito foi feita, separando-se o dataset em alto, médio e baixo risco, com base nos resultados do modelo de *random forest*. Os resultados foram expostos da mesma maneira que foram expostos no estudo, a fim de facilitar a comparação entre o modelo construído e modelo estudado.

### 6.1.2 Estudo 2

Foi construído o modelo de U-NET utilizando a biblioteca Keras. O encoder estruturado está representado na figura 6.1, enquanto o decoder estruturado está representado na figura 6.2. Foram utilizadas 1.879 imagens para o treino e teste da rede em proporção de 9/1, respectivamente. Foi utilizada uma função de ativação do Sigmoid e uma função de *loss* de *binary crossentropy* para otimização do modelo, para uma previsão binária entre floresta e não floresta.

A entrada do modelo foi configurada para imagens de 80x80, assim todas as imagens foram divididas

anteriormente à inserção no modelo, resultando em 17.288 imagens de treino e 1.921 imagens de teste; a divisão e pré processamento das imagens foram feitos com a biblioteca Rasterio.

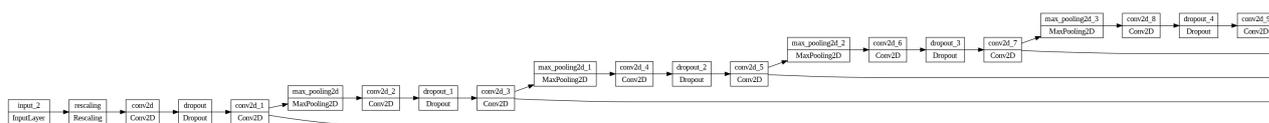


Figura 6.1: Estrutura do Encoder

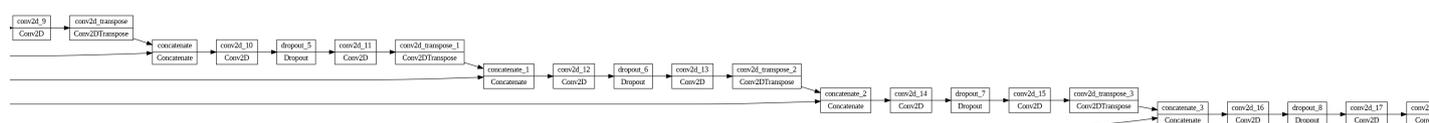


Figura 6.2: Estrutura do decoder

## 6.2 Resultados

### 6.2.1 Estudo 1

Os resultados obtidos para cada um dos anos foram expostos na tabela 6.1. As localizações de cada polígono de cada classe prioritária para os anos de 2019 a 2022 foram representadas nas imagens 6.3,6.5,6.7 e 6.9, utilizando a biblioteca Matplotlib.Os polígonos da classe de baixa prioridade estão representados em branco, enquanto polígonos da classe de média prioridade estão representados em cinza e os polígonos de alta prioridade estão representados em preto. Nas imagens 6.4,6.6,6.8 e 6.10, estão representadas as áreas dos municípios inclusos no Plano Amazônia ??, onde as cores seguem a mesma classificação descrita.

Observa-se certa coerência dos resultados obtidos, visto que estão na mesma faixa daqueles encontrados pelos autores do estudo.O incremento anual no desmatamento concentrados em cada faixa segue aquele encontrado pelos autores do estudo. A área classificada como alto risco abrangem uma faixa de 70% a 67% do incremento do desmatamento anual em uma área de aproximadamente 420.000Km2 assim como nos estudo em que foi baseado.A área e incremento no desmatamento encontrados para os polígonos de médio e baixo risco também estão dentro das faixas encontradas pelos autores do estudo.

Algumas diferenças foram encontradas, Nota-se que os municípios contidos no Plano Amazônia abrangem somente de 2% a 3% do incremento no desmatamento e uma área 2 vezes maior que a área abrangida na classificação de alto risco de desmatamento. Enquanto os autores do estudo encontraram em torno de 37% do incremento do desmatamento na área abrangida pelo municípios do plano amazônia Os resultados encontrados estão expostos na tabela e figuras a seguir.

		Alto	Médio	Baixo	Plano Amazônia
2019	Área total (Km2)	426,848	853,982	3,002,702	808,712
	Incremento no desmatamento previsto (Km2)	7,219	2,704	370	293
	Incremento Anual no desmatamento (%)	70	26	3	2,8
2020	Área total (Km2)	426,588	853,957	3,002,986	808,712
	Incremento no desmatamento previsto (Km2)	7,421	2,852	351	281
	Incremento Anual no desmatamento (%)	69	27	4	2,6
2021	Área total (Km2)	426,817	853,892	3,002,822	808,712
	Incremento no desmatamento previsto (Km2)	8,605	3,717	499	393
	Incremento Anual no desmatamento (%)	67	28	3	3
2022	Área total (Km2)	426,858	853,785	3,002,888	808,712
	Incremento no desmatamento previsto (Km2)	9,682	4,292	524	388
	Incremento Anual no desmatamento (%)	67	29	3.61	2,6

Tabela 6.1: Área das classes prioritárias definidas pelo algoritmo construído e pelo Plano Amazônia(PA), de 2019 até 2022, além do incremento anual no desmatamento previsto em cada divisão.

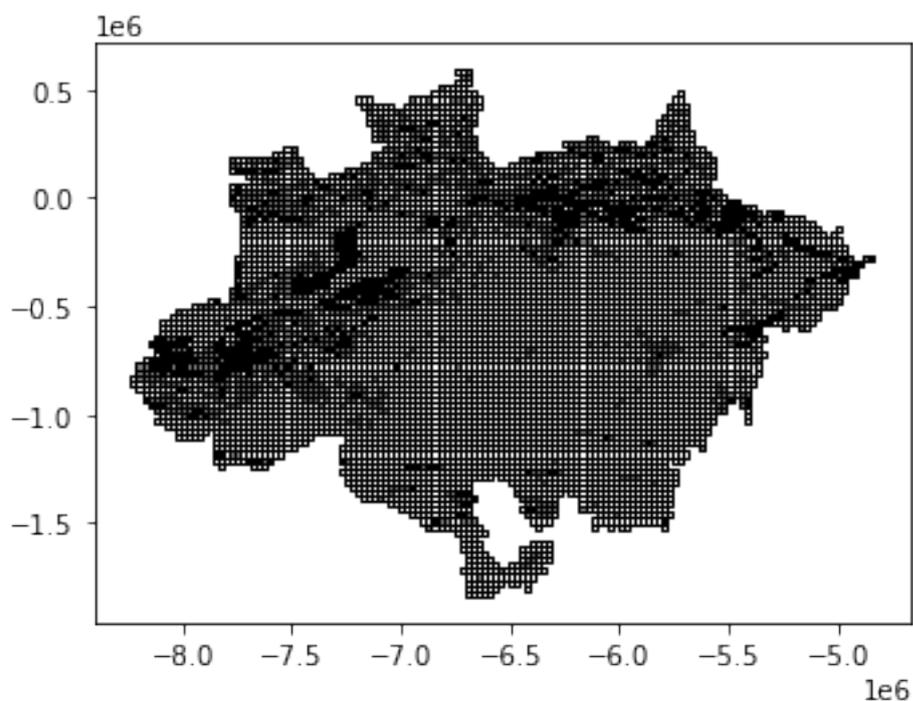


Figura 6.3: Classificação de cada polígono da Amazônia para o ano de 2019

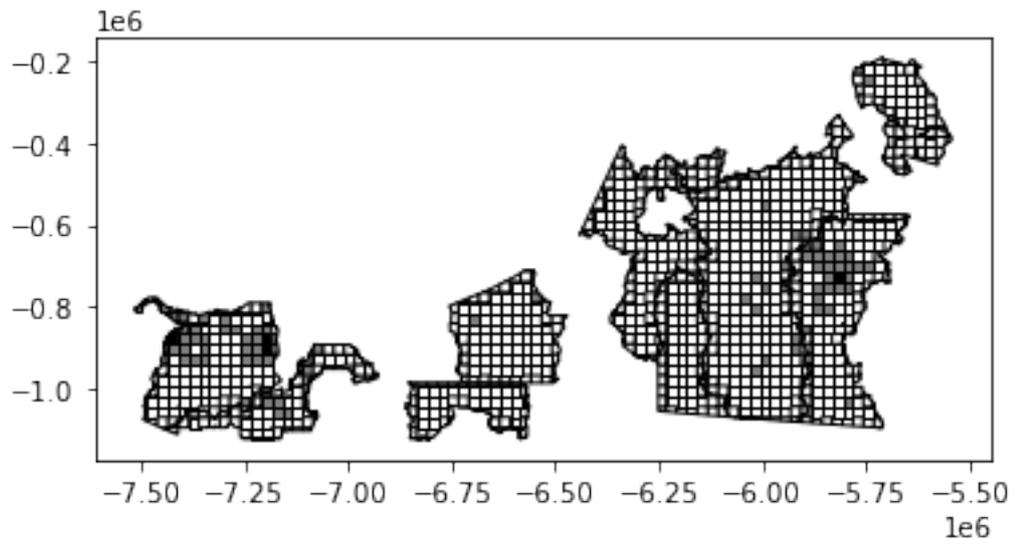


Figura 6.4: Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2019

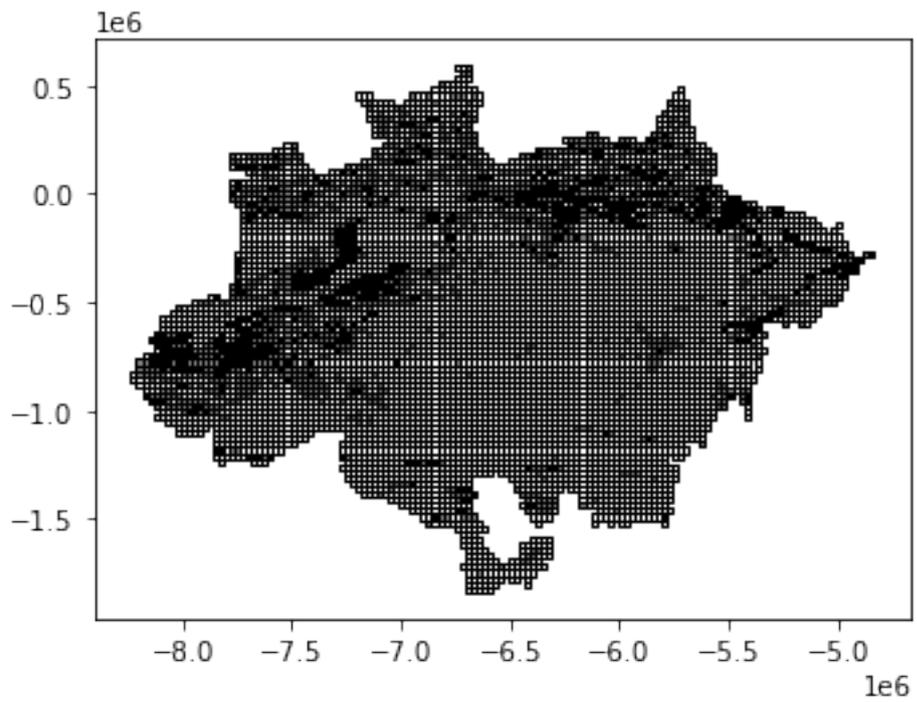


Figura 6.5: Classificação de cada polígono da amazônia para o ano de 2020

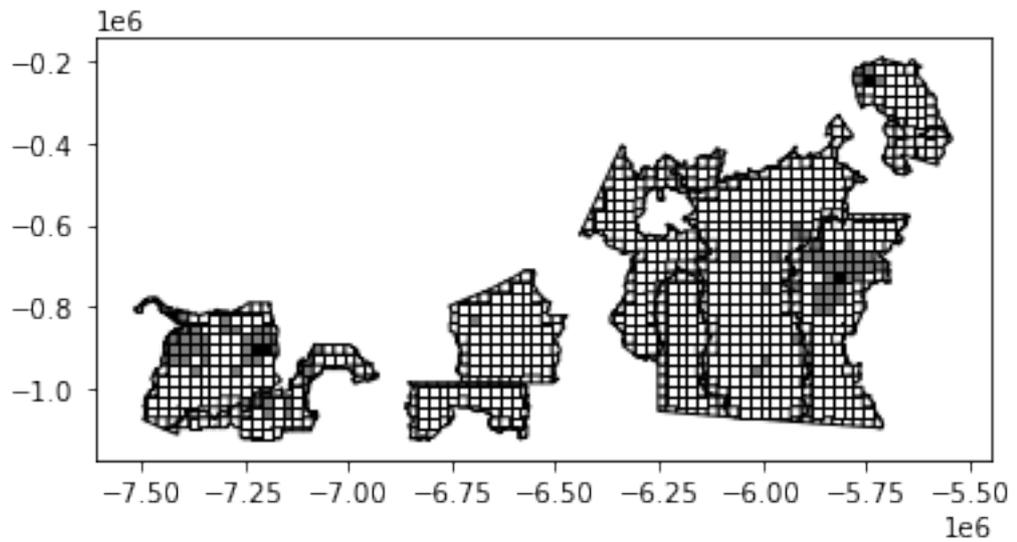


Figura 6.6: Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2020

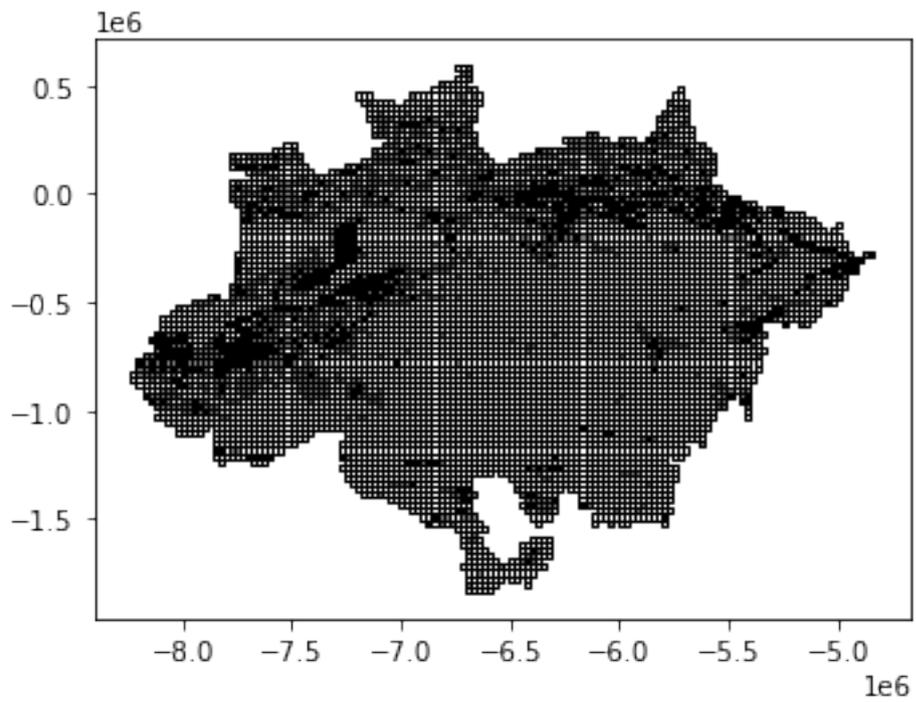


Figura 6.7: Classificação de cada polígono da amazônia para o ano de 2021

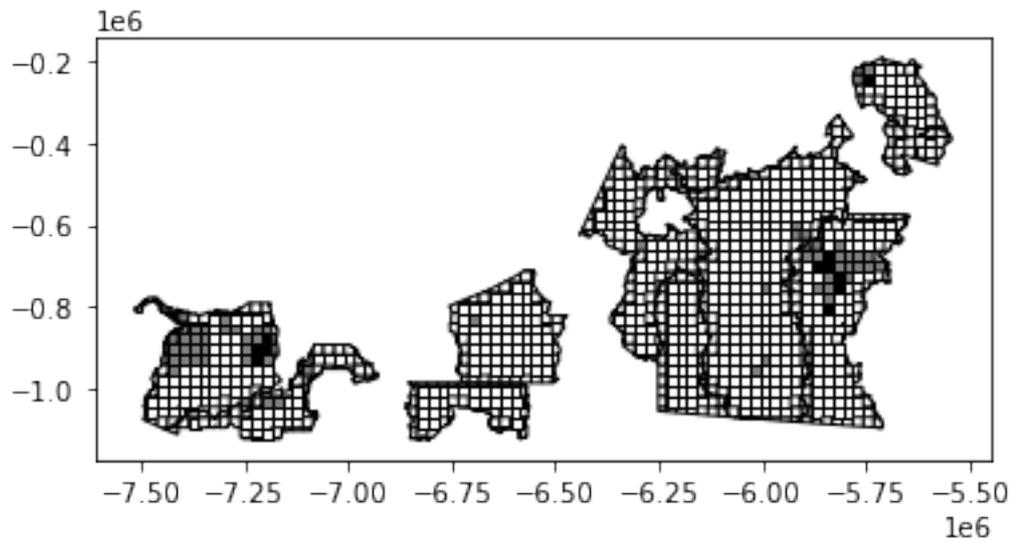


Figura 6.8: Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2021

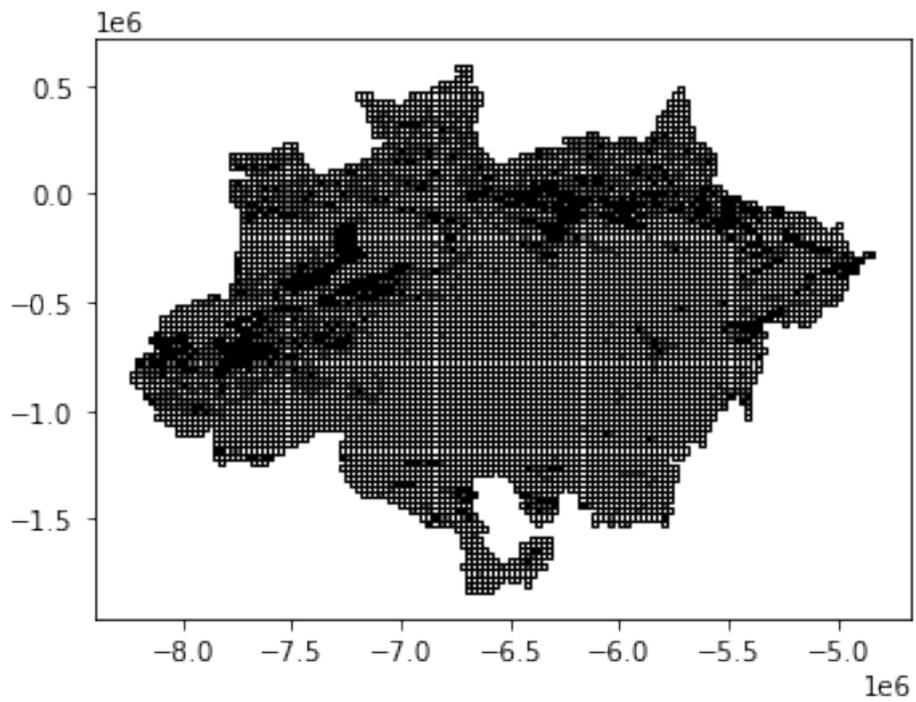


Figura 6.9: Classificação de cada polígono da amazônia para o ano de 2022

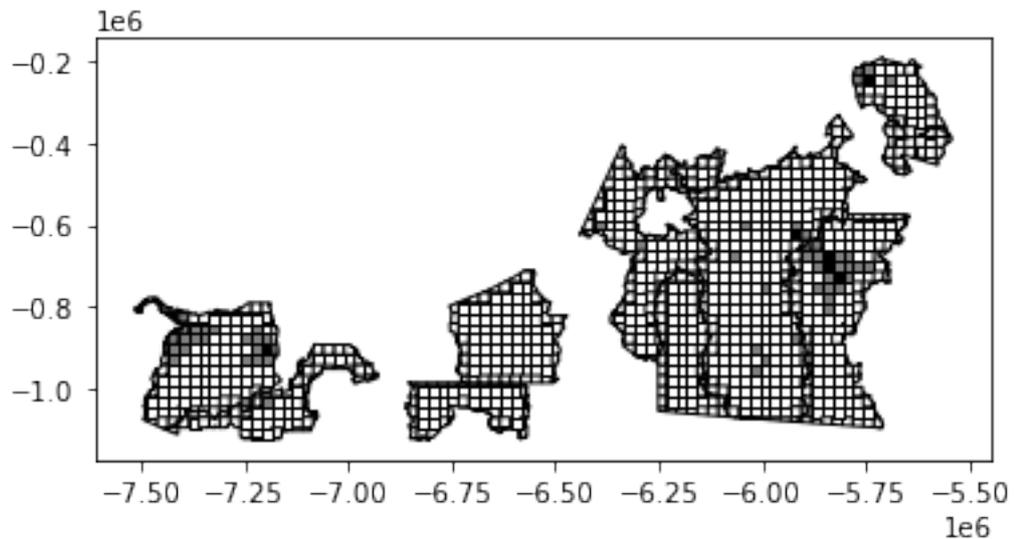


Figura 6.10: Incremento do desmatamento nos Municípios do Plano Amazônia no ano de 2022

Com base no dataset de teste, consegue-se medir o erro do modelo para que possa se aferir sua confiabilidade. Os erros encontrados foram relativamente baixos, mostrando que o modelo teve sucesso em prever o desmatamento em cada ano. Os erros e a acurácia do modelo foram descritos na tabela 6.2.

Erros calculados	
Erro Médio Absoluto	0.9833593948743518
Erro médio quadrático	11.013178149021112
Raiz do Erro Médio Quadrático	3.318610876409150
Coefficiente de Determinação(R <sup>2</sup> )	68,6%

Tabela 6.2: Erros do modelo construído

O Erro Médio Absoluto representa a média das diferenças absolutas entre os valores previstos pelo modelo e os valores reais da variável alvo. É uma medida que expressa o erro médio de previsão, na mesma unidade da variável em questão, assim o modelo difere em aproximadamente  $1Km^2$  dos valores reais.

O Erro médio quadrático (EMQ) é a média dos quadrados das diferenças entre os valores previstos e os valores reais da variável alvo. Ele penaliza de forma mais intensa os erros maiores em relação aos menores. Para a análise realizada, o EMQ é de aproximadamente 11.013, denotando que, em média, o erro quadrático de previsão é de cerca de 11.013. Sua raiz é expressa na mesma unidade da variável alvo. Essa métrica fornece uma medida da magnitude típica dos erros de previsão. Para o modelo avaliado, o REQM é de aproximadamente  $3.319km^2$ .

O Coeficiente de Determinação, também conhecido como R<sup>2</sup>, representa a proporção da variância da variável dependente que é explicada pelas variáveis independentes do modelo. Ele mede a qualidade do ajuste do modelo aos dados e a capacidade de explicar a variância na variável alvo. O R<sup>2</sup> varia de 0 a 1, sendo que um valor de 0 indica que o modelo não explica nenhuma variância, enquanto um valor de 1

indica um ajuste perfeito aos dados. Neste estudo, o  $R^2$  é de aproximadamente 0.686, o que significa que o modelo é capaz de explicar cerca de 68.6% da variância na variável alvo. Tais coeficientes demonstram uma boa aproximação da variável alvo realizada pelo modelo, porém também apresentam uma oportunidade de melhoria ao modelo.

Outro fator importante a se olhar no modelo é o peso que cada uma das colunas trouxe para a previsão, permitindo conferir a importância de cada uma das características. Assim, pode-se compreender melhor como o modelo operou para buscar identificar algum possível problema com o modelo. Nota-se uma vez que as colunas de desmatamento acumulado em anos anteriores possuem quase 75% do peso na tomada de decisão do modelo, mostrando uma fragilidade para a detecção de novos focos de desmatamento isolados. A importância de cada coluna foi descrita na tabela 6.3.

coluna	Importância
Desmatamento Acumulado 4 Anos Anteriores (km <sup>2</sup> )	0.438321
Desmatamento Acumulado 2 Anos Anteriores (km <sup>2</sup> )	0.264343
Distância Hidrovia (km)	0.064316
Desmatamento Ano Anterior (km <sup>2</sup> )	0.051490
Área Protegida	0.025066
Distância Rodovia (km)	0.024121
Focos de Calor Ano Anterior	0.023410
Distância Rodovia + Hidrovia (km)	0.023136
Distância a ponto de grade > 2% desmatamento acumulado em 2 anos (km)	0.006947
Distância a ponto de grade > 1% desmatamento no ano anterior (km)	0.004702

Tabela 6.3: Contribuição de cada coluna para o modelo construído

## 6.2.2 Estudo 2

A evolução dos parâmetros ao final de cada *epoch* foram expostos na tabela 6.4. Os resultados atingidos foram satisfatórios, tendo o modelo atingido uma alta acurácia na segmentação das imagens. A evolução da acurácia e do *loss* foram expostos nos gráficos 6.11 e 6.12 respectivamente, utilizando a biblioteca Matplotlib.

Em termos do contexto de aprendizado de máquina, o termo "loss" (perda) refere-se a uma métrica que quantifica o erro entre as previsões feitas pelo modelo e os valores reais dos dados de treinamento. A perda indica o quão longe as previsões estão dos valores reais e é uma medida fundamental utilizada para otimizar os parâmetros do modelo durante o processo de treinamento. Minimizar a perda é o objetivo principal da etapa de treinamento, pois isso significa que o modelo está se ajustando melhor aos dados e melhorando suas previsões. Portanto, a análise do valor de perda é uma parte crucial da avaliação do desempenho e da capacidade de generalização do modelo.

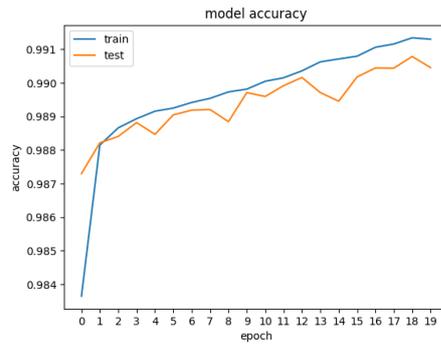


Figura 6.11: Performance da *accuracy* durante o treinamento do modelo

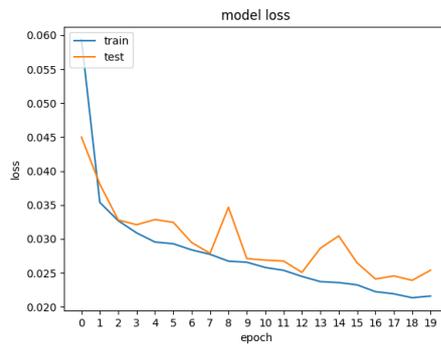


Figura 6.12: Performance do *loss* durante o treinamento do modelo

Tabela 6.4: Resultados de Treino

Epoch	Accuracy	Loss	Test_Accuracy	Test_Loss
0	0.9836	0.0594	0.9873	0.0450
1	0.9881	0.0354	0.9882	0.0381
2	0.9887	0.0327	0.9884	0.0328
3	0.9889	0.0309	0.9888	0.0321
4	0.9892	0.0295	0.9885	0.0329
5	0.9892	0.0293	0.9890	0.0324
6	0.9894	0.0284	0.9892	0.0295
7	0.9895	0.0277	0.9892	0.0279
8	0.9897	0.0267	0.9888	0.0347
9	0.9898	0.0266	0.9897	0.0271
10	0.9900	0.0258	0.9896	0.0269
11	0.9902	0.0254	0.9899	0.0267
12	0.9904	0.0245	0.9902	0.0251
13	0.9906	0.0237	0.9897	0.0286
14	0.9907	0.0236	0.9895	0.0304
15	0.9908	0.0232	0.9902	0.0265
16	0.9911	0.0222	0.9904	0.0241
17	0.9912	0.0219	0.9904	0.0246
18	0.9913	0.0213	0.9908	0.0239
19	0.9913	0.0216	0.9905	0.0254

As 230 imagens restantes foram escolhidas de modo a concentrar a maior porcentagem possível das classes com baixa frequência; enquanto as imagens de treino e teste possuíam 1% de seus valores como não floresta, as imagens de validação possuem 10% de seus valores como não floresta, afim de testar se mesmo com um dataset de treino com classes desbalanceadas, o modelo manteria sua alta acurácia em datasets com mais presença da classe não floresta. O parâmetro do modelo final utilizando as imagens de validação estão expostos na tabela 6.5. Nota-se que, mesmo em datasets com a maior presença de classes não floresta, o modelo mantém a qualidade de seus parâmetros.

Tabela 6.5: Resultados de validação

Metric	Value
Validation Loss	0.0229
Validation Accuracy	0.9911

Procurando-se verificar a eficiência do modelo, foram testadas duas imagens com maior presença de valores da classe não floresta. A primeira imagem possuía muitos rios, onde valores da classe não floresta compõe 28% da imagem. A segunda imagem é a imagem com maior presença de valores da classe não floresta, aproximadamente 47% da imagem é composta por áreas naturais inundáveis, classificada como

não floresta. As imagens e suas predições foram expostas nas figuras 6.13,6.14, utilizando a biblioteca Matplotlib.

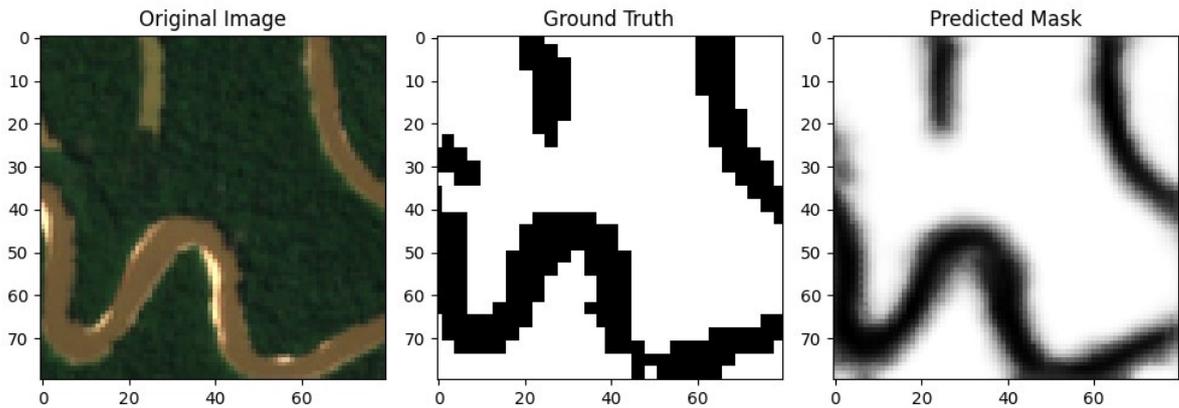


Figura 6.13: Segmentação realizada para imagem com alta presença de rios

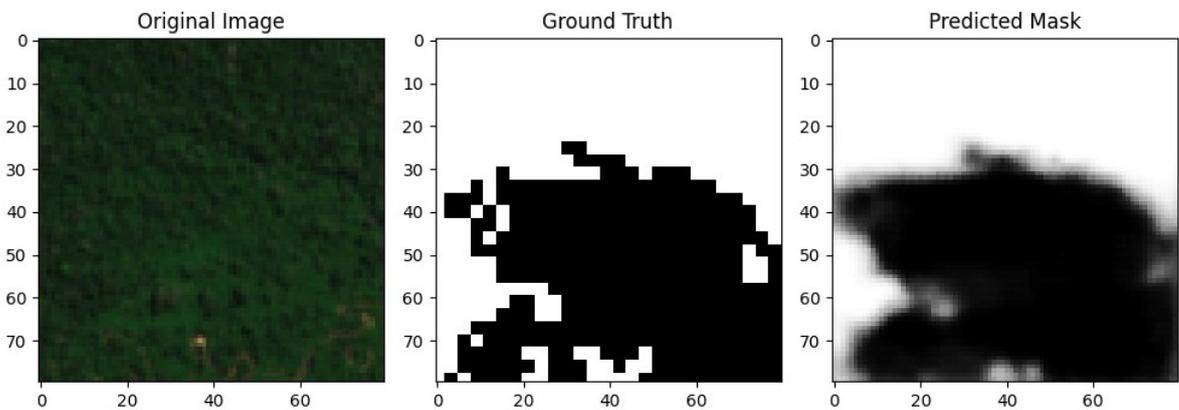


Figura 6.14: Segmentação realizada para imagem com alta presença de áreas inundáveis

Nota-se que, mesmo em imagens com altas porcentagens da classe não floresta, o modelo não apresenta queda em seu rendimento, realizando a correta segmentação das imagens. Ainda ressalta-se que, mesmo em classes em que suas composições RGB apresentam certa semelhança com a classe floresta, o modelo mantém a correta segmentação.

Para Verificar sinais de *overfitting*, foi aplicado o método *K-fold*, juntou-se os *datasets* de treino teste e validação, separando-os posteriormente em 10 partes aproximadamente iguais.O modelo foi treinado e testado 10 vezes onde em cada vez 1 parte diferente do *dataset* foi usada como *dataset* de teste.Os resultados foram expostos na tabela 6.6.

Fold	Accuracy	Loss
1	0,9863	0,2075
2	0,9896	0,0285
3	0,9898	0,0278
4	0,9897	0,0290
5	0,9893	0,0308
6	0,9885	0,0301
7	0,9895	0,0281
8	0,9896	0,0295
9	0,9846	0,2336
10	0,9881	0,0326

Tabela 6.6: Resultados de Accuracy e Loss utilizando validação cruzada com 10 folds.

Assim, constata-se que mesmo com um *dataset* desbalanceado, o modelo não apresentou sinais de *overfitting*, visto que em todos os folds o modelo apresentou resultados semelhantes com uma alta taxa de acurácia e uma baixa taxa de loss. Uma das razões para isso é que o modelo de *U-NET* realiza a segmentação pixel a pixel; então, mesmo que somente 1% dos pixels pertenciam a classe não floresta, isto ainda representava um grande volume de dados. As 17.288 imagens de treino representam 110.643.200 pixels; assim, havia aproximadamente 1.106.432 pixels da classe não floresta, sendo suficiente para a aprendizagem do modelo.

## 7 | Conclusão

Conclui-se que os resultados obtidos no modelo de Random Forest construído são condizentes com a situação real, devido ao baixo valor dos erros encontrados e a sua semelhança quando comparados com os resultados encontrados no estudo relacionado<sup>4</sup>.

Observando-se os municípios classificados como de alto risco, nota-se uma maior quantidade de aumento do desmatamento para uma área menor do que aquelas descritas nas diretrizes do Plano Amazônia, expondo uma deficiência em tal plano. Enquanto as áreas de alto risco abrangem em torno de 70% do incremento do desmatamento em uma área de aproximadamente 420.000 Km<sup>2</sup>, os municípios do Plano Amazônia abrangem 2% do incremento do desmatamento em uma área de de aproximadamente 800.000 Km<sup>2</sup>.

Dessa forma, tem-se as diretrizes do plano Amazônia como insuficientes para a correta defesa da Floresta Amazônica, sendo necessária uma melhor priorização nos territórios da amazônia legal. Técnicas de *machine learning*, como o modelo de *random forest*, se mostram como poderosas ferramentas no combate ao desmatamento, mostrando melhores resultados quando comparados àqueles obtidos a partir das diretrizes do Plano Amazônia 2021/2022.

É importante destacar que, quando analisadas as contribuições de cada atributo para o modelo, percebe-se que as colunas com maiores pesos são as colunas que dizem respeito ao desmatamento naquela região em anos anteriores. Assim, pode-se dizer que o modelo apresenta algum grau de incerteza a respeito de novos focos de desmatamento, o que representa uma oportunidade de melhoria no estudo referenciado neste documento.

A respeito das imagens das análises feitas no Sentinel-2, nota-se que o desempenho do modelo se mostrou como excelente, visto a alta *accuracy* atingida e o baixo *loss* encontrado. A evolução da acurácia e da perda, representadas nas Figuras 6.11 e 6.12, respectivamente, reforçam ainda mais a eficácia do modelo.

Os resultados de validação, apresentados na Tabela 6.5 e nas imagens 6.13 e 6.14, destacam a robustez do modelo quando aplicado a um conjunto de dados com uma presença significativa de classes não florestais. Apesar da maior proporção de valores não florestais nas imagens de validação, o modelo mantém uma acurácia de validação notável e alcança uma baixa perda de validação. Nota-se que mesmo nas imagens com as duas maiores frequências da classe não floresta, o modelo manteve a correta segmentação das imagens. Isso indica que o desempenho do modelo não foi afetado pelo desequilíbrio na distribuição de classes,

evidenciando que, mesmo treinado por um dataset desbalanceado, o modelo não apresentou *overfitting*.

Os resultados obtidos deste estudo fornecem informações valiosas sobre a capacidade do modelo de classificar e segmentar com precisão áreas florestais e não florestais na região do Vale do Javari. A capacidade do modelo de manter o desempenho em paisagens diversas, incluindo áreas com composições RGB semelhantes à classe florestal, é especialmente notável. É importante ressaltar que, com um dataset melhor balanceado, não seria necessário unir as classes não florestais, possibilitando uma segmentação multiclasse, e assim seria possível expandir ainda mais as capacidades do modelo.

Em resumo, o modelo desenvolvido apresenta um desempenho sólido, oferecendo grande potencial para diversas aplicações, como mapeamento de cobertura terrestre, monitoramento ecológico e esforços de conservação na região do Vale do Javari. A segmentação precisa de áreas florestais e não florestais pode contribuir para uma melhor compreensão e gestão desse valioso ecossistema.

## 7.1 Trabalhos Futuros

Este estudo teve como objetivo desenvolver soluções com o objetivo de auxiliar no combate ao desmatamento na região amazônica, propondo duas visões diferentes, utilizando tipos de dados diferentes sobre o tema. Existem algumas oportunidades para melhorar os resultados obtidos neste estudo; assim, seguem possíveis trabalhos futuros para aprimorar a detecção de desmatamento:

- **Melhoria do Conjunto de Dados:** coletar e rotular um conjunto de dados mais abrangente e equilibrado, que abranja várias classes de interesse na região do Vale do Javari.
- **Segmentação Multiclasse:** implementar uma segmentação multiclasse para incluir outras categorias além de áreas florestais e não florestais. Isso requer um conjunto de dados balanceado e rotulado adequadamente.
- **Avaliação de Outros Modelos:** explorar e comparar o desempenho de outros modelos de segmentação e outros modelos de U-NET, como FCN, DeepLab e Mask R-CNN.
- **Análise de Mudanças Temporais:** realizar uma análise de mudanças ao longo do tempo nas áreas florestais e não florestais do Vale do Javari, comparando imagens de satélite de diferentes períodos.
- **Melhorias no modelo de Random Forest:** o modelo apresentou boas métricas porém elas apresentam uma oportunidade de melhora visto as discrepâncias encontradas em relação ao estudo original além das métricas de erro que poderiam ser melhorados.
- **Integração dos modelos:** investigar a integração dos modelos propostos, possibilitando a integração de dados visuais com dados auxiliares, como informações topográficas, climáticas e socioeconômicas, para aprimorar a precisão e a robustez da segmentação de áreas florestais.

# Bibliografia

- [Adams 1982] Adams, T. A. (1982). *Raster data structures and topographic data*. PhD thesis, Durham University.
- [Bowman et al. 2021] Bowman, K. W., Dale, S. A., Dhanani, S., Nehru, J., and Rabishaw, B. T. (2021). Environmental degradation of indigenous protected areas of the amazon as a slow onset event. *Current Opinion in Environmental Sustainability*, 50:260–271. Slow Onset Events related to Climate Change.
- [BR ] BR, G. Flora brasileira. <https://www.gov.br/cnpq/pt-br/assuntos/noticias/pesquisa-do-dia/a-flora-do-brasil-2020-lanca-seus-dados#:~:text=A%20Plataforma%20re%C3%BAne%20descri%C3%A7%C3%B5es%2C%20chaves,e%20fungos%20nativos%20do%20Brasil.&text=55%25%20das%20esp%C3%A9cies%20de%20plantas,ocorrem%20exclusivamente%20em%20territ%C3%B3rio%20brasileiro..> Accessed: 2022-09-21.
- [Breiman 2001] Breiman, L. (2001). Random forests. *Machine learning*, 45:5–32.
- [Cioffi et al. 2020] Cioffi, R., Travaglioni, M., Piscitelli, G., Petrillo, A., and De Felice, F. (2020). Artificial intelligence and machine learning applications in smart production: Progress, trends, and directions. *Sustainability*, 12(2).
- [Danehpash 2015] Danehpash, S. (2015). Evaluation of standards and techniques for retrieval of geospatial raster data: a study for the icos carbon portal. *Student thesis series INES*.
- [Demertzis et al. 2023] Demertzis, K., Demertzis, S., and Iliadis, L. (2023). A selective survey review of computational intelligence applications in the primary subdomains of civil engineering specializations. *Applied Sciences*, 13(6).
- [Dietterich 2000] Dietterich, T. G. (2000). An experimental comparison of three methods for constructing ensembles of decision trees: Bagging, boosting, and randomization. *Machine Learning*, 40:139–157.
- [Du et al. 2020] Du, G., Cao, X., Liang, J., Chen, X., and Zhan, Y. (2020). Medical image segmentation based on u-net: A review. *Journal of Imaging Science and Technology*.

- [Fendrich et al. 2020] Fendrich, A. N., Barretto, A., de Faria, V. G., de Bastiani, F., Tenneson, K., Guedes Pinto, L. F., and Sparovek, G. (2020). Disclosing contrasting scenarios for future land cover in brazil: Results from a high-resolution spatiotemporal model. *Science of The Total Environment*, 742:140477.
- [Gallant et al. 1990] Gallant, S. I. et al. (1990). Perceptron-based learning algorithms. *IEEE Transactions on neural networks*, 1(2):179–191.
- [Grecco ] Grecco, R. M. Medium. <https://rafaelgrecco.medium.com/detec%C3%A7%C3%A3o-de-pneumonia-com-deep-learning-b362c1837c26>. Accessed: 2023-07-20.
- [Han 1303] Han, D. (2013/03). Comparison of commonly used image interpolation methods. In *Proceedings of the 2nd International Conference on Computer Science and Electronics Engineering (ICCSEE 2013)*, pages 1556–1559. Atlantis Press.
- [Han and Moraga 1995] Han, J. and Moraga, C. (1995). The influence of the sigmoid function parameters on the speed of backpropagation learning. In *From Natural to Artificial Neural Computation: International Workshop on Artificial Neural Networks Malaga-Torremolinos, Spain, June 7–9, 1995 Proceedings 3*, pages 195–201. Springer.
- [IBAMA ] IBAMA. Fauna brasileira. <https://www.gov.br/ibama/pt-br/assuntos/noticias/2021/fauna-brasileira-tem-mais-de-100-mil-especies#:~:text=De%20acordo%20com%20dados%20do,e%20flora%20do%20planeta%20Terra>. Accessed: 2022-09-21.
- [John and Zhang 2022] John, D. and Zhang, C. (2022). An attention-based u-net for detecting deforestation within satellite sensor imagery. *International Journal of Applied Earth Observation and Geoinformation*, 107:102685.
- [Koehrsen ] Koehrsen, W. medium. <https://williamkoehrsen.medium.com/random-forest-simple-explanation-377895a60d2di>. Accessed: 2023-07-20.
- [Konovalenko et al. 2022] Konovalenko, I., Maruschak, P., Brezinová, J., Prentkovskis, O., and Brezina, J. (2022). Research of u-net-based cnn architectures for metal surface defect detection. *Machines*, 10(5).
- [LATTARO ] LATTARO, A. ann. <https://imasters.com.br/devsecops/redes-neurais-artificiais-o-que-sao-onde-vivem-do-que-se-alimentam>. Accessed: 2023-07-20.
- [Liu et al. 2015] Liu, L., Shen, C., and Van den Hengel, A. (2015). The treasure beneath convolutional layers: Cross-convolutional-layer pooling for image classification. In *Proceedings of the IEEE conference on computer vision and pattern recognition*, pages 4749–4757.
- [Malhi et al. 2008] Malhi, Y., Roberts, J. T., Betts, R. A., Killeen, T. J., Li, W., and Nobre, C. A. (2008). Climate change, deforestation, and the fate of the amazon. *Science*, 319(5860):169–172.

- [Mansano ] Mansano, A. F. O que é uma rede neural convolucional? <https://www.linkedin.com/pulse/o-que-%C3%A9-um-rede-neural-convolucional-alex-fernandes-mansano/?originalSubdomain=pt>. Accessed: 2023-07-20.
- [Mataveli et al. 2022] Mataveli, G., de Oliveira, G., Chaves, M. E., Dalagnol, R., Wagner, F. H., Ipia, A. H., Silva-Junior, C. H., and Aragão, L. E. (2022). Science-based planning can support law enforcement actions to curb deforestation in the brazilian amazon. *Conservation Letters*, page e12908.
- [Neves et al. 2017] Neves, A., Körting, T., Fonseca, L., Queiroz, G., Vinhas, L., Ferreira, K., and Escada, M. (2017). Terraclass x mapbiomas: Comparative assessment of legend and mapping agreement analysis.
- [O’Shea and Nash 2015] O’Shea, K. and Nash, R. (2015). An introduction to convolutional neural networks. *arXiv preprint arXiv:1511.08458*.
- [Phiri et al. 2020] Phiri, D., Simwanda, M., Salekin, S., Nyirenda, V. R., Murayama, Y., and Ranagalage, M. (2020). Sentinel-2 data for land cover/use mapping: A review. *Remote Sensing*, 12(14).
- [Pérez-Hoyos et al. 2017] Pérez-Hoyos, A., Rembold, F., Kerdiles, H., and Gallego, J. (2017). Comparison of global land cover datasets for cropland monitoring. *Remote Sensing*, 9(11).
- [Reis ] Reis, B. laboratório mobilis. <http://www2.decom.ufop.br/imobilis/redes-neurais-funcoes-de-ativacao/>. Accessed: 2023-07-20.
- [Segarra et al. 2020] Segarra, J., Buchaillet, M. L., Araus, J. L., and Kefauver, S. C. (2020). Remote sensing for precision agriculture: Sentinel-2 improved features and applications. *Agronomy*, 10(5).
- [Silva 2020] Silva, J. O. (2020). O isolamento é possível? o caso de um povo de recente contato do vale do javari. *Cadernos de Campo (São Paulo - 1991)*, 29(supl):244–254.
- [TerraBrasilis ] TerraBrasilis. Terra brasilis. <http://terrabrasilis.dpi.inpe.br/en/home-page/>. Accessed: 2022-09-21.
- [Thöny 2017] Thöny, M. (2017). *Interactive visualization of large-scale geographic data*. PhD thesis, University of Zurich.
- [Thöny et al. 2018] Thöny, M., Billeter, M., and Pajarola, R. (2018). Large-scale pixel-precise deferred vector maps. In *Computer Graphics Forum*, volume 37, pages 338–349. Wiley Online Library.
- [Tickle 2013] Tickle, A. (2013). Tickle, alex, "uncontacted peoples of the javari valley, brazil"(2013). anthropology senior theses. paper 137. 29:137.
- [Ying 2019] Ying, X. (2019). An overview of overfitting and its solutions. *Journal of Physics: Conference Series*, 1168(2):022022.

[Zou et al. 2009] Zou, J., Han, Y., and So, S.-S. (2009). Overview of artificial neural networks. *Artificial neural networks: methods and applications*, pages 14–22.