# UNIVERSIDADE FEDERAL DE MATO GROSSO DO SUL CAMPUS DE TRÊS LAGOAS PROGRAMA DE PÓS GRADUAÇAO EM GEOGRAFIA

JOÃO OTAVIO NASCIMENTO FIRIGATO

FORESTRYVIEW APP: MAPEAMENTO DA SILVICULTURA COM USO DE SENSORES REMOTOS, DEEP LEARNING E COMPUTAÇÃO EM NUVEM

#### JOÃO OTAVIO NASCIMENTO FIRIGATO

## FORESTRYVIEW APP: MAPEAMENTO DA SILVICULTURA COM USO DE SENSORES REMOTOS, DEEP LEARNING E COMPUTAÇÃO EM NUVEM

Dissertação apresentada ao Programa de Pósgraduação – Mestrado em Geografia/CPTL/UFMS – Área de Concentração Análise Geoambiental e Produção do Território, uma das exigências para a obtenção do título de Mestre em Geografia, sob orientação do Prof°. Dr°. Vitor Matheus Bacani.

#### JOÃO OTAVIO NASCIMENTO FIRIGATO

# FORESTRYVIEW APP: MAPEAMENTO DA SILVICULTURA COM USO DE SENSORES REMOTOS, DEEP LEARNING E COMPUTAÇÃO EM NUVEM

Dissertação apresentada ao Programa de Pósgraduação – Mestrado em Geografia/CPTL/UFMS – Área de Concentração Análise Geoambiental e Produção do Território, uma das exigências para a obtenção do título de Mestre em Geografia, sob orientação do Prof°. Dr°. Vitor Matheus Bacani.

Resultado:	
Três Lagoas, MS, de	de 2021.
	BANCA EXAMINADORA
O	rientador: Prof. DR. Vitor Matheus Bacani UFMS
1	Prof. DR. Carlos Antonio da Silva Júnior UNEMAT
	Prof. DR. José Marcato Junior UFMS
	Prof. DR. André Luiz Pinto

**UFMS** 

#### **DEDICATÓRIA**

Dedico este trabalho aos meus familiares, que me deram apoio e suporte durante esta jornada, e a todos os pesquisadores deste país, que lutam diariamente contra a desvalorização da ciência nacional.

#### **AGRADECIMENTOS**

Agradeço primeiramente a minha esposa Isabela, por ter me apoiado nesse caminho, a minha mãe, meu pai e minha irmã também pelo apoio. Agradeço ao Professor Vitor por ter se dedicado a me orientar para a construção deste trabalho, agradeço a banca, Prof. Marcato, Prof. Carlos e Prof. André, pelas valiosas contribuições. Agradeço também aos colegas de trabalho na UFMS pelo suporte. Agradeço a PROGEP pelo incentivo e apoio a capacitação do servidor, e a própria UFMS em geral.

"Vivemos em uma sociedade extremamente dependente da ciência e tecnologia, na qual pouquíssimos sabem alguma coisa sobre ciência e tecnologia. Isto é uma clara prescrição para o desastre."

(Why We Need To Understand Science - Carl Sagan)

#### **RESUMO**

O mapeamento de uso e cobertura da terra é uma importante ferramenta de monitoramento de alterações no espaço geográfico. A partir desse mapeamento é possível a extração de informações que possibilitam compreender a evolução paisagística de uma determinada área ou região. O estado da arte na classificação digital de imagens de satélite são os algoritmos de aprendizado profundo baseados em redes neurais convolucionais que foram suportados pelo surgimento de plataformas de computação em nuvem, onde é possível a obtenção de uma grande quantidade de dados geoespaciais e do alto poder de processamento utilizados no processo de treinamento desses algoritmos. Este trabalho teve como objetivo mapear áreas de silvicultura na mesorregião leste do estado do Mato Grosso do Sul, a partir do uso de modelos de aprendizagem profunda para a segmentação semântica, disponibilizando os resultados desse mapeamento através de um aplicativo acessível pela internet. Os procedimentos metodológicos fundamentaram-se na utilização de uma base de dados com 1320 imagens do sensor MSI do satélite Sentinel 2A para os meses de maio, julho e setembro de 2019 a fim de se obter uma maior variação espectral dos alvos durante o ano, considerando as classes silvicultura e não-silvicultura. Foram utilizados 960 amostras para treinamento, 180 amostras para validação e 180 para teste. Esses dados alimentam a rede neural, extraindo as características das imagens de treinamento, a fim de gerar um modelo que possibilita a predição de rótulos para o restante da região de estudo. Os resultados obtidos para o modelo final apresentaram uma acurácia global de 98% para os dados de teste, possibilitando a predição do mapeamento de toda a área de estudo para os anos de 2017, 2018, 2019 e 2020. Para a disponibilização dos mapeamentos, um aplicativo foi criado na plataforma Google Earth Engine, possibilitando a acessibilidade e a interatividade com informações de índices espectrais como o NDVI, o SAVI, o EVI, dentre outros. Assim, a combinação entre computação em nuvem, deep learning e sensoriamento remoto se mostra altamente promissora para a obtenção de produtos e análises geoespaciais, essenciais no âmbito do planejamento ambiental e socioeconômico da área de estudo.

**Palavras-chave**: Google earth engine, segmentação semântica, uso e cobertura da terra, redes neurais convolucionais.

#### **ABSTRACT**

Mapping land use and land cover is an important tool for monitoring changes in geographic space. From this mapping, it is possible to extract information that makes it possible to understand the landscape evolution of a certain area or region. The state of the art in digital classification of satellite images are deep learning algorithms based on convolutional neural networks that were supported by the emergence of cloud computing platforms, where it is possible to obtain a large amount of geospatial and high power data processes used in the training process of these algorithms. This work aimed to map silviculture areas in the eastern mesoregion of the state of Mato Grosso do Sul, using deep learning models for semantic segmentation, making the results of this mapping available through an application accessible on the internet. The methodological procedures were based on the use of a database with 1320 images from the Sentinel 2A satellite MSI sensor for the months of May, July and September 2019 in order to obtain a greater spectral variation of the targets during the year, considering the forestry and non-forestry classes. 960 samples were used for training, 180 samples for validation and 180 for testing. These data feed the neural network, extracting the characteristics of the training images, in order to generate a model that enables the prediction of labels for the rest of the study region. The results obtained for the final model showed an overall accuracy of 98% for the test data, making it possible to predict the mapping of the entire study area for the years 2017, 2018, 2019 and 2020. For the availability of the mappings, a The application was created on the Google Earth Engine platform, allowing accessibility and interactivity with information from spectral indexes such as NDVI, SAVI, EVI, among others. Thus, the combination of cloud computing, deep learning and remote sensing is highly promising for obtaining geospatial products and analyzes, which are essential in the context of the environmental and socioeconomic planning of the study area.

**Key-words:** Google earth engine, semantic segmentation, land use and land cover, convolutional neural networks.

#### LISTA DE FIGURAS

Figura 1 - Reflectância espectral de diferentes materiais encontrados na superfície terrestre. 29
Figura 2 - Distribuição de pixels de vegetação no espaço espectral vermelho x infravermelho
próximo e sua trajetória durante o ciclo fenológico
Figura 3 - Esquematização das camadas de convolução e pooling em uma rede neural37
Figura 4 - Representação da operação de convolução, onde N filtros são aplicados em uma
imagem com número D de características, gerando N mapas de ativação como saída37
Figura 5 - Representação da operação max pooling
Figura 6 - Arquitetura U-Net para segmentação semântica
Figura 7 - Representação de um bloco residual
Figura 8 - Matriz de Confusão Binária
Figura 9 - Localização da Mesorregião Leste do estado de Mato Grosso do Sul46
Figura 10 - Fluxograma do processo metodológico
Figura 11 – Precipitação média diária por mês e temperatura média diária mês para o ano de
2019
Figura 12 - Precipitação média diária por mês e temperatura média diária mês dos últimos 20
anos
Figura 13 - Curva espectral dos diferentes tipos de uso e cobertura no mês de setembro de
2019 (A) e no mês de maio de 2019 (B)
Figura 14 - Distribuição espacial das regiões de amostragem
Figura 15 - Processo de geração dos polígonos delimitando regiões que contém silvicultura.
A) Delimitação feita no Google Earth Engine. B) Validação visual pelo mapeamento de uso e
cobertura de 2018 feito pelo Mapbiomas. C) Validação com imagem de alta resolução do
Google Maps53
Figura 16 - Exemplo de amostra coletada. A) imagem RGB do satélite Sentinel 2. B) máscara
representando áreas de silvicultura
Figura 17 - Comparativo entre a arquitetura resnet 101 e a modificação utilizada no
codificador
Figura 18 - Fatiamento da área de estudo em janelas para predição do modelo57
Figura 19 - Matriz de Confusão dos resultados do conjunto de treinamento59
Figura 20 - Matriz de Confusão dos resultados do conjunto de validação
Figura 21 - Matriz de Confusão dos resultados do conjunto de teste
Figura 22 - Matriz de Confusão das amostras referentes ao período úmido61
Figura 23 - Matriz de Confusão das amostras referentes ao período intermediário62

Figura 24 - Matriz de Confusão das amostras referentes ao período seco	62
Figura 25 - Comparação visual dos resultados para a amostra 2	65
Figura 26 - Comparação visual dos resultados para a amostra 6	66
Figura 27 - Comparação visual dos resultados para a amostra 7.	67
Figura 28 - Comparação visual dos resultados para a amostra 17	86
Figura 29 - Comparação visual dos resultados para a amostra 21	69
Figura 30 - Comparação visual dos resultados para a amostra 26.	70
Figura 31 - Comparação visual dos resultados para a amostra 34	71
Figura 32 - Comparação visual dos resultados para a amostra 38	72
Figura 33 - Comparação visual dos resultados para a amostra 43	73
Figura 34 - Comparação visual dos resultados para a amostra 48.	74
Figura 35 - Comparação visual dos resultados para a amostra 53	75
Figura 36 - Comparação visual dos resultados para a amostra 60	76
Figura 37 - Área total de silvicultura mapeada para a região de estudo	77
Figura 38 - Quantidade de áreas incorporadas pela silvicultura sem descontar as perdas	78
Figura 39 - Apresentação visual do ForestryView App	79
Figura 40 - NDVI mensal das áreas de silvicultura.	80
Figura 41 - Estimativa de altura de árvores nas áreas de florestas plantadas para o ano	de
2019	80
Figura 42 - Mapa de ganhos de áreas de silvicultura anual	81

### LISTA DE EQUAÇÕES

$NDVI = \frac{\rho IVP - \rho VERM}{\rho IVP + \rho VERM} \tag{1} \dots$	31
$EVI = G \frac{\rho IVP - \rho VERM}{L + \rho IVP + C1 \rho VERM - C2 \rho AZUI}$	(2)31
$SAVI = \frac{\rho IVP - \rho VERM}{\rho IVP + \rho VERM + L} (1 + L)$	(3)31
$NDRE = \frac{\rho IVP - \rho RE}{\rho IVP + \rho RE} \tag{4} \dots$	31
$NDWI = \frac{\rho IVP - \rho IVM}{\rho IVP + \rho IVM} $ (5)	32
$NDMI = \frac{\rho IVP - \rho IVM}{\rho IVP + \rho IVM} \tag{6}$	32
$GVMI = \frac{(\rho IVP + 0.1) - (\rho IVM + 0.02)}{(\rho IVP + 0.1) + (\rho IVM + 0.02)}$	(7)32
$Acur\'{a}cia = \frac{(TP + TN)}{(TP + TN + TP + TN)}$	(8)42
$Precisão = \frac{TP}{TP + FP} $ (9)	43
$Recall = \frac{TP}{TP + FN} \tag{10} \dots$	43
$     \text{Indice de Jaccard} = \frac{\text{TP}}{(\text{TP} + \text{TP})} $	
	,

#### LISTA DE TABELAS

Tabela 1. Critérios de avaliação do grau de concordância baseada no ír	ndice	Kappa
(CONGALTON e GREEN, 1999).		44
Tabela 2. Métricas de validação por dataset		58
Tabela 3. Métricas de validação para os períodos climáticos		60
Tabela 4. Comparação das métricas de validação entre os resultados por período	climát	ico.61
Tabela 5. Resultados por amostra		63

#### **SIGLAS E ABREVIATURAS**

**CNN:** Convolutional Neural Network

ESA: European Space Agency

**EVI:** Enhanced Vegetation Index

FCN: Fully Convolutinal Network

**GEE:** Google Earth Engine

**GFCH:** Global Forest Canopy Height

**GPS:** Global Position System

**GPU:** Graphics Processing Unit

**GVMI:** Global Vegetation Moisture Index

IBGE: Instituto Brasileiro de Geografia e Estatística

**IoU:** Intersection over Union

LiDAR: Light Detection And Ranging

**MODIS:** Moderate Resolution Imaging Spectroradiometer

NDRE: Normalized Difference Red-Edge Index

**NDMI:** Normalized Difference Moisture Index

**NDVI:** Normalized Difference Vegetation Index

**PEVS:** Produção da Extração Vegetal e Silvicultura

**RADAR:** Radio Detection And Ranging

ReLU: Rectified Linear Unit

RNA: Redes Neurais Artificiais

**SAVI:** Soil Adjusted Vegetation Index

**SVM:** Suport Vector Machines

**TOA:** Top Of Atmosphere

### SUMÁRIO

1 INTRODUÇÃ	O	24
2 <b>OBJETIVO</b>		25
2.1 Objetivo Geral		
2.2 Objetivos Esp	pecíficos	25
3 <b>FUNDAMEN</b>	ΓΑÇÃO TEÓRICA METODOLÓGICA	25
3.1 Geotecnologia	as	26
3.2 SIGs e Sensor	riamento Remoto	27
3.3 Comportamen	nto espectral da vegetação	29
3.3.1	Índices espectrais	31
3.4 Classificação	de imagens	32
3.4.1	Classificação não supervisionada	33
3.4.2	Classificação supervisionada	33
3.4.3	Segmentação clássica	34
3.5 Aprendizado	de máquina	34
3.6 Aprendizado profundo		35
3.7 Redes neurais convolucionais		
3.8 Segmentação	Semântica	39
3.9 Métricas de v	alidação	41
3.9.1	Matriz de confusão	42
3.9.2	Acurácia Global	42
3.9.3	Precisão	43
3.9.4	Recall	43
3.9.5	Índice de similaridade de Jaccard	43
3.9.6	Índice Kappa	44
3.10 Webmaps		44
4 METODOLO	GIA	46
4.1 Definição da	região de estudo.	46
4.2 Fluxograma		47
4.3 Análise climá	tica e espectral da região de estudo	47
4.4 Aquisição do	dataset	50
4.4.1	Definição das características espectrais, espaciais e temporais	52
4.4.2	Delimitação das áreas de silvicultura presente nas imagens	52

	4.4.3	Exportação das máscaras e imagens para o Google Drive	53
4.5 Treinam	ento d	o modelo de segmentação semântica	54
	4.5.1	Preparação do dataset	54
	4.5.2	Definição da arquitetura da rede neural	55
	4.5.3	Treinamento da rede neural	56
4.6 Obtenção	o do m	apeamento	56
5 RESULT	CADOS	S E DISCUSSÃO	58
5.1 Resultad	dos ger	ais	58
<b>5.</b> 2 Resultad	dos de	validação por período	60
<b>5.</b> 3 Resultad	os de v	validação por amostras	62
5.4 Resultad	os dos	mapeamentos	76
	<b>5.</b> 4.1 E	Disponibilização do mapeamento pelo Google Earth Engine Apps	78
<b>5.5</b> Discussã	.o		81
6 CONSID	ERAÇ	ÇÕES FINAIS	83
7 <b>REFERÎ</b>	ÈNCIA	S BIBLIOGRÁFICAS	84

#### 1 INTRODUÇÃO

A Geografia utiliza-se frequentemente da representação gráfica dos elementos naturais e antrópicos presentes em uma determinada área em um mapeamento de uso e cobertura da terra. O uso e cobertura da terra é essencial para análise de padrões de organização do espaço e a compreensão das dinâmicas socioeconômicas e ambientais que se desenrolam no mesmo, permitindo a visualização e identificação dos elementos geometricamente apresentados. Por meio das geotecnologias, é possível facilitar a sintetização dos diferentes tipos de uso e cobertura da terra em mapas, inclusive para mapeamentos que abrangem diversos municípios.

Nas últimas décadas o leste de Mato Grosso do Sul destacou-se como uma das regiões onde o plantio de eucalipto mais tem se fortalecido, devido principalmente a fatores econômicos, como a instalação de indústrias de celulose, e também ambientais, como solo e relevo favoráveis ao plantio e mecanização da colheita, juntamente com a abundância de recursos hídricos (SÃO MIGUEL, 2016).

Segundo dados do projeto Mapbiomas (SOUZA et al., 2020), desde 1985 a região vem sofrendo significativas alterações de uso e cobertura da terra, amplificadas desde 2007 pela expansão da silvicultura, sendo assim, de suma importância o mapeamento preciso dessas alterações para possíveis análises ambientais multitemporais.

Uma maneira de obtenção de um mapeamento temático preciso é a classificação digital por pixels, onde um algoritmo rotula cada pixel da imagem de satélite em classes de acordo com sua curva espectral. É possível utilizar desde os algoritmos mais tradicionais de classificação como distância mínima, máxima verossimilhança, paralelepípedo (SILVA; PEREIRA, 2007) até os mais avançados que utilizam o aprendizado de máquina (TALUKDAR et al., 2020). No entanto a classificação baseada em pixel, considera apenas a variação espectral das bandas de cada pixel, deixando de lado informações importantes da imagem como como textura, forma, bordas, vizinhança, etc.. Abordagens como a OBIA (Object-Based Image Classification) possibilitam o uso dessas informações espaciais, mas a seleção das características a serem adicionadas ao classificador é realizada manualmente e o contexto utilizado é no nível do segmento apenas (TASSI; VIZZARI, 2020).

Deste modo, os algoritmos de aprendizado profundo, principalmente as redes neurais convolucionais, são o estado da arte para extração automática dessas características. A segmentação semântica se utiliza desse poder para separar os pixels da imagem em classes (GARCIA-GARCIA et al., 2017), como por exemplo uma classificação binária entre áreas de florestas plantadas e outros tipos de coberturas, resultando em máscaras da classe prédefinida.

Baseado no avanços de novas tecnologias como o *big data* e a computação em nuvem, o Google Earth Engine é uma plataforma de código livre que hospeda petabytes de diferentes tipos de dados geoespaciais, simplificando o acesso, processamento e disponibilização de análises e produtos de sensoriamento remoto através da Web (TAMIMINIA et al., 2020).

Busca-se assim, nos diversos caminhos atrelados as geotecnologias – neste caso o uso de computadores e da Web - grandes aliados para a evolução e o desenvolvimento da produção e disponibilização de mapas temáticos, com o intuito de contribuir para a preservação de ecossistemas, recuperação de áreas degradadas, e subsidiar políticas e planos de ações locais, possibilitando o melhor desenvolvimento social do sujeito, buscando o equilíbrio entre as relações homem e natureza.

#### 2 OBJETIVO

#### 2.1 Objetivo Geral

O objetivo principal deste trabalho é mapear e disponibilizar online as áreas de silvicultura na mesorregião leste do estado de Mato Grosso do Sul, a partir do uso de imagens orbitais e modelos de aprendizagem profunda para a segmentação semântica dessas áreas.

#### 2.2 Objetivos Específicos

- Construir e ajustar uma arquitetura de redes neurais convolucionais, a fim de se obter melhores resultados na precisão de áreas do mapeamento de áreas de silvicultura.
- Avaliar o modelo gerado com diferentes métricas de validação.
- Avaliar o modelo para os três períodos do ano predefinidos.
- Delimitar as áreas de silvicultura na mesorregião leste do estado do Mato Grosso do Sul utilizando dados do satélite Sentinel 2 para os anos de 2017, 2018, 2019 e 2020.
- Disponibilizar informações de índices espectrais, produtos e análises derivadas do satélite Sentinel 2 das áreas segmentadas.

#### 3 FUNDAMENTAÇÃO TEÓRICA METODOLÓGICA

O desenvolvimento da referente pesquisa fundamentou-se na construção de um referencial teórico-metodológico, que servirá como apoio para toda sua execução, assim como a análise dos resultados finais.

#### 3.1 Geotecnologias

A área das geociências, na qual se insere a geografia física, é comumente conhecida por abranger conhecimentos aplicados de diversas disciplinas como matemática, física, química, biologia, além da própria geografia. Também conhecidas como Ciências Exatas e da Terra, buscam compreender o espaço e diversos aspectos físicos por meio da interdisciplinaridade e de uma maneira quantitativa.

A rápida evolução da tecnologia no século XX resultou em inovações no campo da geografia. Diversas aplicações como os satélites, a cartografia, o GPS, os computadores, que, eram de uso militar, tornaram-se úteis ao serem introduzidos à análise geográfica. Além disso, o final da década de 1950 representou uma revolução com o surgimento da geografia quantitativa e o uso de modelos matemáticos e estatísticos nos estudos geográficos. Aliandose o uso das geotecnologias com modelos matemáticos e estatísticos, resultou em técnicas mais precisas que englobam uma quantidade de dados e informações muito maiores que as técnicas tradicionais podiam relacionar.

[...] As geotecnologias são compostas por soluções em hardware, software e peopleware que juntos constituem poderosas ferramentas para tomada de decisões (ROSA,2011).

Ainda para Rosa (2011) as geotecnologias, também conhecidas como geoprocessamento, são o conjunto de ferramentas utilizadas na coleta, processamento, análise e disponibilização de informações e dados com referência geográfica. As principais geotecnologias existentes são: o sensoriamento remoto, os sistemas de informação geográfica, a cartografia digital, e o sistema de posicionamento global.

#### 3.2 SIGs e Sensoriamento Remoto

Fitz (2008) argumenta que as geotecnologias são compreendidas como novas tecnologias associadas às áreas afins à geociência, proporcionando aos usuários ações de planejamento, gestão, etc.. Aliados a isto, os Sistemas de Informação Geográfica e o Sensoriamento Remoto são utilizados pela Geografia Física para permitir uma melhor compreensão e análise de fenômenos que ocorrem no espaço geográfico, sendo fundamentais para estudo, ordenamento, planejamento e monitoramento ambiental.

Segundo INPE (2008), o objetivo principal do sensoriamento remoto é a detecção das características de alvos, naturais ou artificias, por meio do fluxo de energia radiante, emitido ou refletido por eles, obtendo informações sobre uma área sem contato direto.

O sensoriamento remoto é uma técnica que utiliza sensores para captação de informações de uma região ou alvo através da radiação eletromagnética emitida por fontes naturais ou artificiais (ROSA, 2005). Para Lillesand e Kieffer (2015) "[...] É a arte e a ciência de estudar a matéria sem ter contato físico com a mesma baseando-se somente da interação da radiação eletromagnética".

Para Jensen (2009) o sensoriamento remoto é o registro dos valores de energia emitidos ou refletidos nas regiões visível, ultravioleta, infravermelho ou micro-ondas do espectro eletromagnético, por diversos instrumentos como câmeras, escâneres multiespectrais ou hiperspectrais, RADAR, LiDAR, etc., em satélites ou aeronaves sem contato, e análise dos dados obtidos visualmente ou pelo processamento digital de imagens.

[...] Utilização conjunta de modernos sensores, equipamentos para processamento de dados, equipamentos de transmissão de dados, aeronaves, espaçonaves, etc., com o objetivo de estudar o ambiente terrestre através do registro e da análise das interações entre a radiação eletromagnética e as substâncias do planeta Terra em suas mais diversas manifestações (NOVO, 1989).

Os diversos satélites que orbitam a terra, captam imagens com diferentes características, dependendo do tipo do satélite quanto do tipo do sensor. As características mais importantes em uma imagem de satélite são: resolução espacial, resolução espectral, resolução radiométrica e resolução temporal (MENESES; ALMEIDA, 2012).

Ainda para Meneses e Almeida (2012) a resolução espacial representa o nível de detalhe que é possível observar na imagem. Ou seja, ele determina o tamanho do menor objeto possível de ser identificado. A resolução radiométrica representa a quantidade de níveis de radiância que o sensor consegue detectar. Quanto maior a resolução radiométrica de um sensor, maiores serão as diferenças de intensidade dos níveis de radiância. A resolução temporal é a frequência com que uma área é observada pelo sensor.

A resolução espectral de um sensor óptico é a característica de discriminar objetos em relação da sua sensibilidade espectral (FLORENZANO, 2011). Ou seja, quanto mais bandas espectrais com intervalos estreitos e em diferentes regiões espectrais o sensor possuir, maior a capacidade de diferenciar as reflectâncias emitidas pelos objetos da superfície.

Assim, a resolução espectral é considerada a característica mais determinante para a diferenciação dos tipos de materiais presentes na superfície terrestre, pois cada material tem valores de reflectância diferentes dependendo da faixa espectral, conforme a Figura 1;

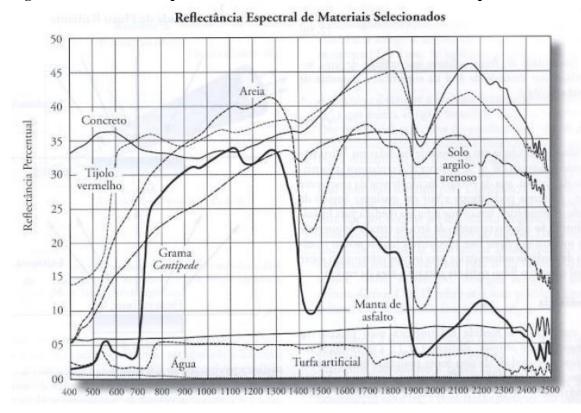


Figura 1 - Reflectância espectral de diferentes materiais encontrados na superfície terrestre.

Fonte: Jensen, 2009.

#### 3.3 Comportamento espectral da vegetação

A vegetação é um dos principais alvos em aplicações de sensoriamento remoto, sendo utilizados para análise e estudos de áreas florestais, agrícolas e vegetação urbana (SILVA, 2012). A partir dos dados obtidos por sensores remotos, é possível a implementação de técnicas que buscam compreender a resposta espectral de uma área coberta de vegetação. Essa resposta é causada por uma complexa iteração entre a radiação eletromagnética e fatores estruturais e ambientais dos diversos elementos do dossel vegetativo (PONZONI, 2002).

A folha é o principal elemento que interage com a radiação eletromagnética, sendo que a reflectância pode ser influenciada por alguns elementos como pigmentos, estruturas celulares, espaços celulares ocupados por água ou ar, quantidade de água, idade, condição de iluminação, etc. (SILVA, 2012).

Jensen (2009) demonstra que a biomassa da vegetação está relacionada com as respostas espectrais da faixa do vermelho e do infravermelho próximo. Para o vermelho essa relação é inversamente proporcional, ou seja quanto maior o dossel, menor o valor da

reflectância. Já para o infravermelho próximo, a relação é proporcional, tendo maiores valores de reflectância para dosséis maiores. Em relação ao solo exposto, a umidade é um fator que tem uma influência inversamente proporcional à reflectância do vermelho e do infravermelho próximo. A figura 2 apresenta graficamente essa relação, além de adicionar o ciclo fenológico e a umidade como outros fatores variáveis.

Distribuição de Pixels no Trajetória de um Pixel no Grande Espaço Espectral Vermelho Espaço Espectral Vermelho x Grande fechamento fechamento Infravermelho Próximo x Infravermelho Próximo do dossel (muita do dossel (alta Durante o Ciclo biomassa) biomassa) Fenológico da Vegetação Quase adulto Fechamento Reflectáncia no Infravermelho Próximo Fechamento intermediário do intermediário do dossel (média Solo exposto dossel (média Solo exposto biomassa) biomassa) seco seco Nenhuma vegetação presente inha do Solo Linha do Solo Vegetação colhida: nenhuma vegetação presente, solo seco Plantio: nenhuma vegetação presente Solo exposto Solo exposto (solo úmido) úmido úmido Reflectância no Vermelho Reflectância no Vermelho

Figura 2 - Distribuição de pixels de vegetação no espaço espectral vermelho x infravermelho próximo e sua trajetória durante o ciclo fenológico.

Fonte: Jensen ,2009.

Para Ponzoni (2002), além dos fatores apresentados acima, a arquitetura da vegetação também influencia na resposta espectral. Ou seja, diferentes tipos de vegetação, em diferentes estágios de desenvolvimento e com distribuições de plantios em diversos formatos afetam valores de reflectância da vegetação. Um exemplo disso é em florestas densas com diferentes camadas de altura de árvores, onde ocorre o sombreamento das camadas mais inferiores, diminuindo o valor da resposta obtida pelo sensor orbital. Isso não ocorre em áreas com eucalipto, já que não possuem tantas camadas.

Assim, Maranha et al. (2017), ao utilizar imagens obtidas pelo sensor OLI do satélite Landsat 8 para traçar o comportamento espectro-temporal de áreas com eucaliptos em diferentes estágios, junto com dados de precipitação, obtiveram resultados que mostram a influência desses fatores nas curvas de reflectância de cada banda espectral e nos índices de vegetação presentes no estudo.

#### 3.3.1 Índices espectrais

Dentre os principais índices de vegetação propostos pela literatura, o *Normalized Difference Vegetation Index* (NDVI) proposto por Rouse et al. (1973), se destaca como um dos mais utilizados no realce da vegetação, sendo definido como a razão entre a diferença e a soma entre o infravermelho próximo e o vermelho (Equação 1).

$$NDVI = \frac{\rho IVP - \rho VERM}{\rho IVP + \rho VERM} \tag{1}$$

Huete et al. (1997), propôs o *Enhanced Vegetation Index* (EVI), que modifica o NDVI através da utilização de coeficientes e da banda azul, minimizam o efeito da atmosfera e do solo (Equação 2).

$$EVI = G \frac{\rho IVP - \rho VERM}{L + \rho IVP + C1 \rho VERM - C2 \rho AZUL}$$
 (2)

O *Soil Adjusted Vegetation Index* (SAVI), proposto por Huete et al. (1988), é um melhoramento do NDVI, através de um fator *L* que ajusta a interferência causada pela interação da radiação eletromagnética com o solo (Equação 3).

$$SAVI = \frac{\rho IVP - \rho VERM}{\rho IVP + \rho VERM + L} (1 + L)$$
(3)

Outro índice de vegetação muito utilizado é o *Normalized Difference Red-Edge Index* (NDRE) (BARNES et al., 2000) que é calculado através da razão entre a diferença e a soma do infravermelho próximo e a borda do vermelho (Equação 4).

$$NDRE = \frac{\rho IVP - \rho RE}{\rho IVP + \rho RE} \tag{4}$$

O *Normalized Difference Water Index* (NDWI) (GAO, 1996), representa o conteúdo de água interna da vegetação e é definido como a razão entre a diferença e a soma do infravermelho próximo com o infravermelho médio (Equação 5).

$$NDWI = \frac{\rho IVP - \rho IVM}{\rho IVP + \rho IVM} \tag{5}$$

O NDWI também é conhecido como *Normalized Difference Moisture Index* (NDMI), e utiliza a mesma formulação (Equação 6), que neste trabalho será diferenciado do índice anterior pelo uso da banda B11 para o infravermelho médio.

$$NDMI = \frac{\rho IVP - \rho IVM}{\rho IVP + \rho IVM} \tag{6}$$

O *Global Vegetation Moisture Index* (GVMI) (CECCATO et al., 2002), também se utiliza das bandas do infravermelho próximo e médio mas com fatores de ajuste para estimar a humidade da vegetação (Equação 7).

$$GVMI = \frac{(\rho IVP + 0.1) - (\rho IVM + 0.02)}{(\rho IVP + 0.1) + (\rho IVM + 0.02)}$$
(7)

#### 3.4 Classificação de imagens

A classificação de imagens pode ser entendida como a transformação de uma imagem multiespectral, formada por diferentes bandas, em uma carta temática, onde os objetos sobre a superfície terrestre são classificados e identificados de acordo com suas características espaciais, espectrais ou temporais, destinando cada pixel a uma determinada classe ou categoria anteriormente definida pelo pesquisador (LILLESAND; KIEFER, 2015).

A classificação digital de imagens surgiu de um processo de automatização da classificação por interpretação visual humana, visando encontrar padrões e critérios que definem os diversos elementos presentes em uma imagem a partir de medidas estatísticas obtidas dos valores espectrais desses elementos utilizando uma regra de decisão para classificá-los em diferentes tipos (MENESES; SANO, 2012).

Os modos de classificação digital de imagens podem ser divididos em relação à interação do analista com algoritmo ou não. Os dois principais métodos referentes a esse relacionamento são a classificação não-supervisionada e a classificação supervisionada (VENTURIERI; SANTOS, 1998).

#### 3.4.1 Classificação não supervisionada

A classificação não supervisionada é definida segundo Tso e Mather (2009) como um método que não requer a interação do analista com o algoritmo classificador. O analista não informa o rótulo das amostras, ficando à cargo do algoritmo defini-los automaticamente. No entanto o analista deve informar alguns parâmetros que o classificador vai utilizar, como o número de classes por exemplo (MOREIRA, 2007).

O treinamento não supervisionado tem o objetivo de encontrar automaticamente os padrões pertencentes aos dados, agrupando os pixels da imagem em clusters com características espectrais similares. Assim, os principais usos desse tipo de treinamento é quando não se conhece o número e os diferentes tipos de classes da área de estudo e quando se deseja fazer um rápido reconhecimento das características espectrais da área (MENESES; SANO, 2012).

#### 3.4.2 Classificação supervisionada

A classificação supervisionada necessita de um conhecimento prévio do analista das classes presentes na área de estudo. Através de amostras de cada tipo de classe, o algoritmo é treinado a fim de distingui-las. Ou seja, no processo de classificação supervisionada, o analista deve coletar um conjunto de pixels representativo espectralmente para cada classe, alimentando um algoritmo que após reconhecer o padrão comportamental dos dados consegue classificar novos conjuntos de dados nas classes pré-definidas (MENESES; SANO, 2012).

Para Moreira (2007), um dos mais importantes procedimentos na classificação supervisionada é a obtenção de pixels puros, pois geralmente a resposta espectral de uma alvo não é homogênea. Além disso, outros fatores influenciam na qualidade da coleta de dados, como alvos diferentes que podem conter comportamento espectral muito semelhantes, alvos de uma mesma classe que apresentam comportamento espectral variável temporalmente, sombras, nuvens e ruídos. Todos esses problemas podem confundir o algoritmo classificador, ocasionando erros na geração de mapeamentos de uso e cobertura.

Sobre a classificação supervisionada Richards e Jia (2006) referem-se como o procedimento mais utilizado para análise quantitativa de dados de imagens de sensoriamento remoto. Para rotular os pixels de uma imagem representando classes específicas de uso ou

cobertura do solo, são utilizados algoritmos de classificação como por exemplo: paralelepípedo, distância mínima, distância de Mahalanobis, máxima Verossimilhança, etc..

#### 3.4.3 Segmentação clássica

A segmentação clássica é uma técnica realizada antes da etapa de classificação, dividindo a imagem em diversos segmentos contendo pixels espectralmente similares, definindo o elemento a ser classificado como segmento e não apenas o pixel isolado. (MOREIRA, 2007).

Meneses e Sano (2012), afirmam que a segmentação de imagens é um método de agrupamento de pixels com características parecidas, a fim de se obter regiões homogêneas de pixels chamados segmentos. Através de um algoritmo de segmentação, a imagem é particionada em regiões de acordo com alguns parâmetros definidos pelo usuário, como a similaridade e o tamanho mínimo de cada segmento. Esse tipo de segmentação consegue produzir índices maiores de precisão na classificação, sendo mais aproximada com a realidade feita manualmente pelo analista, além de evitar ruídos conhecidos como efeito "salt-and-peper", que são pixels ou pequenos conjuntos de pixels de diferentes classes espalhados pela imagem.

#### 3.5 Aprendizado de máquina

Na ciência da computação, de acordo com Luger e Stubblefield (1998) a Inteligência Artificial é o ramo que se preocupa com a automatização de tarefas e comportamentos inteligentes.

Sobre a subárea do Aprendizado de máquina, Faceli et al. (2011) afirmam:

"Com isso, necessita-se que as técnicas sejam capazes de criar por si próprias, a partir do conhecimento adquirido por experiências passadas, uma hipótese que consiga resolver o problema em questão. Esse processo é conhecido como Aprendizado de Máquina (AM)" (FACELI et al., 2011).

Segundo Mitchell (1997), para essas máquinas construírem programas inteligentes, elas devem treinar sobre um conjunto de amostras e utilizar estratégias mais eficientes adquirindo o conhecimento de forma automática a partir do aprendizado pela experiência. Alguns exemplos de algoritmos de aprendizado de máquina são: Redes Neurais Artificiais (RNAs), Algoritmos Genéticos, Árvores de Decisão, Support Vector Machines (SVMs), dentre outros.

Devido as imagens obtidas através do sensoriamento remoto possuírem características que dificultam a compreensão estatística como a alta dimensionalidade, a não-linearidade dos dados, redundância espacial e espectral e a presença de ruídos, o aprendizado de máquina proporcionou um progresso em tarefas que os algoritmos convencionais não se saiam bem (CAMPS-VALLS, 2009).

#### 3.6 Aprendizado profundo

O aprendizado profundo é uma subárea do aprendizado de máquina, composto por algoritmos baseados em redes neurais profundas. Segundo LeCunn (2015) esses algoritmos aprendem os padrões e representações estruturais de grandes volumes de dados, sendo considerados o estado da arte em tarefas como reconhecimento de fala, reconhecimento de objetos, detecção de objetos, classificação de imagens, dentre outras.

Para Reis (2018), um modelo de aprendizado profundo é composto por redes neurais de múltiplas camadas onde cada camada extrai as características mais representativas de um conjunto de dados, de um modo que essas características são usadas nas camadas posteriores para o aprendizado de características cada vez mais complexas. Por exemplo em uma imagem composta por uma matriz de valores de pixels, orientações e arestas são as características extraídas geralmente na primeira camada. Na segunda camada arranjos de arestas podem ser detectados. Assim, nas camadas seguintes combinações cada vez mais complexas de características são detectadas de acordo com os dados fornecidos (LECUNN, 2015).

Já para Marques (2016) a característica de melhorar o seu desempenho após cada iteração se deve ao processo de ajuste dos pesos das redes neurais ocasionando assim uma resposta generalizada para a sua devida tarefa. O principal objetivo desse processo de melhoria de desempenho são boas performances tanto no conjunto de dados de treinamento quanto no conjunto de dados de teste, evitando assim problemas como o *underfitting* (quando o modelo apresenta baixa performance para os dados de treinamento) e o *overfitting* (quando

o modelo apresenta altos resultados para os dados de treinamento mas não tem uma boa performance para os dados de teste) (REIS, 2018).

Com o aumento da disponibilidade de dados e de poder computacional devido a utilização de GPU's (Unidades de Processamento Gráfico) para o processamento, redes neurais com dezenas ou até centenas de camadas e milhões de parâmetros foram sendo construídas, visando a obtenção de resultados cada vez mais precisos (KHRYASHCHEV et al., 2018) conseguindo assim, o estado da arte em diversas tarefas como classificação de imagens (XIE et al., 2020), detecção de objetos (LIU et al., 2019) e segmentação semântica (YUAN et al., 2019).

O aprendizado profundo vem sendo aplicado cada vez mais ao sensoriamento remoto, principalmente pela disponibilidade de grandes volumes de dados, como imagens de satélite fornecidas pelas missões Copernicus e Landsat (ZHU, 2017), e pelo desenvolvimento de algoritmos baseados nas redes convolucionais neurais (CNN), possibilitando ótimos resultados em tarefas como classificação de lavouras por imagens de satélite (SILVA, 2018), segmentação semântica (GHASSEMI et al, 2019), detecção e reconhecimento de objetos em imagens de satélite (CHEN, 2014), dentre outras.

#### 3.7 Redes neurais convolucionais

As redes neurais convolucionais são um tipo de rede neural comumente utilizadas para o processamento de dados em formatos de matrizes (GOODFELLOW et al., 2016), por exemplo imagens digitais. Ainda para Goodfellow et al. (2016), essas redes são formadas por neurônios artificiais interconectados, no qual através de operações nas camadas de convolução e *pooling*, são extraídos os mapas de características das camadas seguintes da rede (Figura 3).

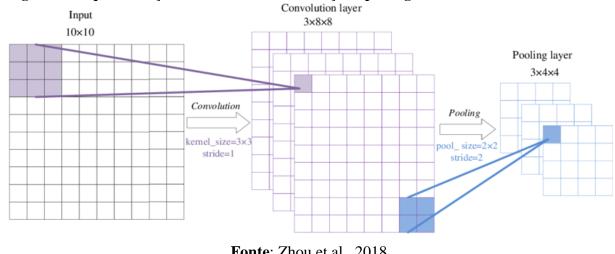


Figura 3 - Esquematização das camadas de convolução e pooling em uma rede neural.

Fonte: Zhou et al., 2018.

A camada de convolução se utiliza de filtros convolucionais de tamanho fixo, movimentados pela imagem ou pelo mapa anterior, realizando operações matemáticas sobre os pixels com valores presentes nos filtros chamados de pesos. A matriz de valores resultantes são os chamados mapas de características (NOGUEIRA, 2019). A Figura 4 representa esse processo.

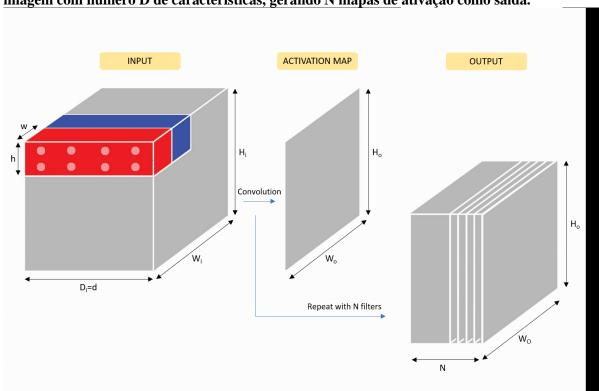


Figura 4 - Representação da operação de convolução, onde N filtros são aplicados em uma imagem com número D de características, gerando N mapas de ativação como saída.

Fonte: Muruganandham, 2016.

Para Carreira (2017) a camada de pooling é usada após a camada de convolução com o objetivo de diminuir a dimensão dos mapas de características evidenciando as principais informações da imagem, como também para redução do número de parâmetros da rede, reduzindo assim o custo computacional. O pooling consiste em uma janela de tamanho definido que percorre o mapa de características extraindo, no caso do max pooling, apenas o maior valor presente nesta subárea (Figura 5). Outra abordagem é o average pooling, onde a média dos valores presentes na subárea é extraída (MURUGANANDHAM, 2016).

y 3 5 2 3
0 8 1 7
4 2 5 4
1 1 9 2
X

Figura 5 - Representação da operação max pooling.

Fonte: Carreira, 2017.

A camada de ativação em uma rede neural convolucional é composta por uma função de ativação. A função de ativação tem como propósito limitar a saída das operações anteriores em um intervalo definido de valores. Nas redes convolucionais geralmente é utilizada a função ReLU (Retified Linear Unit), permitindo ao modelo uma representação de forma não-linear, aumentando a capacidade de aproximação da separação dos dados (REIS, 2018).

#### 3.8 Segmentação Semântica

A técnica de segmentação semântica pode ser definida com um problema onde cada pixel da imagem é agrupado em classes semântica pré-definidas, através de padrões e características aprendidas no treinamento do algoritmo (MURUGANANDHAM, 2016).

Para Marmanis (2016), a segmentação semântica é trabalhada como aprendizado supervisionado, onde através das imagens de treinamento e de suas máscaras rotuladas, o classificador aprender a predizer os rótulos de imagens desconhecidas previamente. Essa abordagem se diferencia das abordagens tradicionais de segmentação de imagens de satélite, onde os pixels são segmentados por um algoritmo não supervisionado, em relação aos níveis de cinza dos pixels adicionados a contornos e bordas (GUO, 2018), ou são segmentados em regiões, e essas regiões são classificadas, sendo a segmentação um pré-processamento da classificação supervisionada (MARUJO, 2013).

Já para Khryashchev et al. (2018) a segmentação de imagem é considerada uma tarefa de classificação por pixel, onde o objetivo é separar os pixels em áreas significativas, feita de maneira manual, podendo ser uma tarefa demorada e dispendiosa, ou de forma automática, graças aos avanços nos algoritmos de Machine Learning e Deep Leaning.

Umas das primeiras arquiteturas utilizadas na segmentação semântica foi a fully convolutional network (FCN), formada por camadas de convolução e pooling para extração das características da imagem e por uma camada de upsampling, que recupera a informação espacial da imagem, recriando o tamanho original da imagem segmentada (LONG et al., 2015).

Ronnenberger et al. (2015) também se utilizaram das redes convolucionais neurais para criar uma arquitetura chamada U-Net (Figura 6) para segmentação semântica de imagens biomédicas. McGlinchy et al. (2019) utilizou-se dessa arquitetura para o mapeamento de áreas urbanas impermeáveis em imagens de alta resolução do satélite WordView-2. Os resultados obtidos demonstraram o potencial do uso da segmentação semântica mapeamentos de alvos em imagens obtidas por satélites.

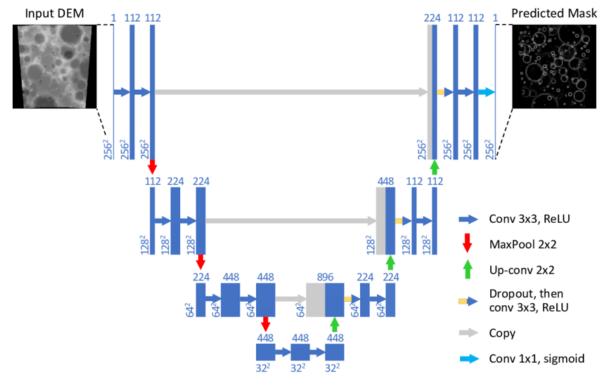


Figura 6 - Arquitetura U-Net para segmentação semântica.

Fonte: Ronnenberger et al., 2015.

A U-Net é dividida em 2 blocos, um codificador que realiza a extração de características da imagem, diminuindo o tamanho dos mapas de ativação e aumentando a quantidade de filtros, e um decodificador que restaura o tamanho inicial da imagem realizando assim a segmentação dos pixels (GHASSEMI et al., 2018).

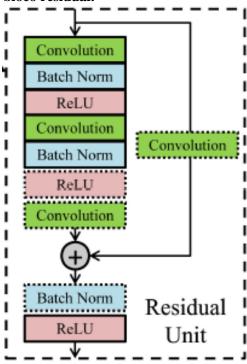
A arquitetura original do codificador é composta de repetições de blocos com camadas de convoluções 3x3, uma camada de ativação e uma camada de pooling 2x2. Já o decodificador é composto por repetições de blocos com camadas de upsampling 2x2, que aumentam o tamanho da imagem, concatenadas com o mapa de características correspondente do codificador, sendo seguidas de camadas de convoluções 3x3 e uma camada de ativação (RONNENBERGER et al., 2015).

No entanto os blocos do codificador e do decodificador podem ser alterados, adicionando diferentes camadas, mudando a quantidade de filtros, etc.. Desta maneira, para segmentação semântica de imagens de satélite Ghassemi et al., (2018) propuseram o uso de uma arquitetura com uma Residual Network ou Resnet (HE et al., 2015) no Codificador, apresentando uma melhora nos resultados em relação à U-Net, baseando-se no aumento de camadas, profundidade da rede e no número de parâmetros. Cao e Zhang (2020), também

obtiveram uma melhor acurácia global ao utilizar-se da arquitetura Res-UNet em comparação a U-Net, na classificação de diferentes espécies de árvores com imagens de alta resolução.

A arquitetura da Resnet é composta por unidades conhecidas como blocos residuais (Figura 7). Essa unidade básica é formada por duas ou três camadas de convoluções e camadas de ativação, sendo que a na última camada de convolução é adicionada como entrada a primeira camada de convolução da unidade. Desta maneira é possível empilhar diversos blocos residuais na arquitetura, garantindo uma grande profundidade da rede mantendo uma quantidade treinável de parâmetros (GHASSEMI et al., 2018).

Figura 7 - Representação de um bloco residual.



Fonte: Ghassemi et al., 2018.

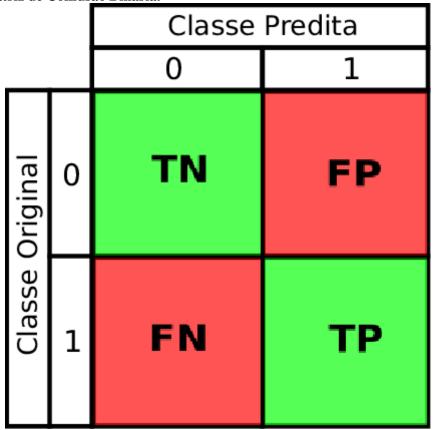
#### 3.9 Métricas de validação

A avaliação da qualidade de uma imagem gerada na tarefa de segmentação semântica pode ser feita por diversas métricas de validação. Entre os mais utilizados estão a acurácia global, a precisão, o recall, o índice de similaridade de Jaccard, a matriz de confusão e o índice Kappa.

#### 3.9.1 Matriz de confusão

Para Provost (1998), a matriz de confusão abriga informações sobre a diferença real e a prevista, feita por um modelo de classificação, e fornece uma visualização do desempenho de um algoritmo (Figura 8). Para uma classificação binária, a matriz de confusão pode ser representada dessa maneira:

Figura 8 - Matriz de Confusão Binária.



Fonte: Bezerra, 2018.

#### 3.9.2 Acurácia Global

A acurácia global mede o número total de pixels classificados corretamente dividido pelo número total de pixels da imagem (Equação 8), definindo o quão certo o modelo consegue classificar (SILVA, 2018).

$$Acur\'{a}cia = \frac{(TP + TN)}{(TP + TN + TP + TN)}$$
(8)

Quando ocorre um desbalanceamento entre classes, por exemplo, na identificação de alvos pequenos ou esparsos, essa métrica é sensível a este desequilíbrio (SARAIVA et al., 2020), sendo necessário utilizar outras métricas mais confiáveis para essas situações.

#### 3.9.3 Precisão

Já a precisão estabelece uma métrica entre todos os pixels classificados como positivo, quanto desses estão classificados corretamente, e é definida pela fórmula:

$$Precisão = \frac{TP}{TP + FP} \tag{9}$$

#### **3.9.4** Recall

O recall, mede a quantidade de pixels classificados como positivo em relação a real quantidade de pixels positivos existentes na amostragem, sendo definido pela fórmula:

$$Recall = \frac{TP}{TP + FN} \tag{10}$$

#### 3.9.5 Índice de similaridade de Jaccard

Também conhecido como IoU (Intersecção sobre União), o índice de similaridade de Jaccard é a medida da semelhança entre a região considerada verdade absoluta e a região prevista pelo modelo para uma determinada imagem (PASHAEI et al., 2020).

Sua fórmula penaliza os falsos positivos através da divisão do número total de pixels classificados corretamente pelo número total de previstos mais o número de verdadeiros (Equação 9) (MALAMBO et al., 2019).

$$\text{Indice de Jaccard} = \frac{\text{TP}}{(\text{TP} + \text{TP} + \text{TN})} 
 \tag{11}$$

#### 3.9.6 Índice Kappa

Uma outra métrica bastante utilizada principalmente em classificações de imagens por sensoriamento remoto é o índice Kappa.

[...] A análise de Kappa é uma técnica multivariada discreta usada na avaliação da precisão temática e utiliza todos os elementos da matriz de confusão no seu cálculo. O coeficiente Kappa (K) é uma medida da concordância real (indicado pelos elementos diagonais da matriz de confusão) menos a concordância por chance (indicado pelo produto total da linha e coluna, que não inclui entradas não reconhecidas), ou seja, é uma medida do quanto à classificação está de acordo com os dados de referência (FIGUEIREDO e VIERA, 2007).

Com base na tabela de grau de concordância do índice kappa (Tabela 1), nos valores totais de acurácia, precisão, sensibilidade e f-score, será realizada a análise dos classificadores, com o objetivo de obter o melhor desempenho possível na classificação supervisionada por pixels. Será analisada também a influência dos ruídos de rótulos nos classificadores e nas métricas em um ambiente de teste controlado.

Tabela 1. Critérios de avaliação do grau de concordância baseada no índice Kappa (CONGALTON e GREEN, 1999).

Valor do Kappa	Concordância
K ≤ 0	Péssimo
$0.0 < K \le 0.2$	Ruim
$0.2 < K \le 0.4$	Razoável
$0.4 < K \le 0.6$	Bom
$0.6 < K \le 0.8$	Muito Bom
$0.8 < K \le 1.0$	Excelente

#### 3.10 Webmaps

Com o avanço das geotecnologias e a popularização da internet, cada vez mais os mapeamentos em formato digital vem sendo empregados como uma opção em relação aos mapas impressos (DESTRO, 2007).

Para Matta (2017), a disponibilização da cartografia digital pela web se deve principalmente a alguns fatores como disponibilidade, custo baixo, popularidade e grande capacidade de atualização, permitindo assim que o usuário acesse e visualize mapas interativos rapidamente atualizados.

Um Webmap permite o acesso à informação geográfica através de uma página da web de uma maneira interativa, sendo possível ao usuário, selecionar diferentes tipos de informações, alterar camadas, observar propriedades de diferentes regiões, aplicar zoom em uma determinada região, etc. (DORMAN, 2020).

Veenedaal et al. (2017) traça a evolução do mapeamento web em eras, onde algumas características descrevem essa evolução, como início da disponibilização em mapas estáticos, passando por mapeamentos dinâmicos, os iterativos, colaborativos, acessados por dispositivos móveis, até os mais atuais que utilizam serviços em nuvem, Big Data e Inteligência Artificial.

O Google Earth Engine (GEE), além de ser uma plataforma de computação em nuvem que permite o acesso a petabytes de dados geoespaciais (GORELICK et al., 2017), também possibilita a criação e disponibilização de uma interface contendo mapeamentos e análises.

Assim, o GEE abriu um leque de oportunidades de desenvolvimento de aplicações voltadas para a análise ambiental, espacial e temporal, integrando diversos tipos de dados em um ambiente único e utilizando processamento em nuvem, contribuindo assim com cientistas e pesquisadores de diversas partes do mundo (KUMAR; MUTANGA, 2018).

Clemente et al. (2020) utiliza a plataforma para avaliar algoritmos para a classificação de campos de cultivos usando dados do Sentinel 1 e do Sentinel 2. Já Hakdaoui et al.(2020) através de algoritmos de aprendizado de máquina e dados de satélite monitoram a salinidade e a umidade de cavidades de água salgada permanente no Marrocos. A plataforma também foi utilizada para a análises e gestão de recursos hídricos, disponibilizando dados e informações espaciais referentes a precipitação (MOTA et al.,2020).

Apesar das vantagens da utilização da plataforma, algumas limitações como por exemplo a falta de funções ou bibliotecas para construção e processamento de modelos de Deep Learning dentro do plataforma em JavaScript (AMANI et al., 2020), fazem com que a integração da API em Python com outras plataformas do própria Google como o Google Colab e o Google Drive, seja um caminho interessante a ser seguido.

#### 4 METODOLOGIA

## 4.1 Definição da região de estudo.

Este estudo abrange a mesorregião leste do estado do Mato Grosso do Sul (Figura 9), definida segundo o IBGE (2019). Essa mesorregião é dividida em quatro microrregiões, abrangendo os seguintes municípios: Cassilândia, Chapadão do Sul, Costa Rica, Paraíso das Águas, Aparecida do Taboado, Inocência, Paranaíba, Selvíria, Água Clara, Brasilândia, Ribas do Rio Pardo, Santa Rita do Pardo, Três Lagoas, Anaurilândia, Bataguassu, Batayporã, Taquarussu e Nova Andradina.

A escolha da área de estudo se deve pelas grandes alterações do uso e cobertura ao longo dos 15 últimos anos, principalmente no aumento da área de formações florestais plantadas, por conta da expansão do plantio de eucalipto no leste do estado (IBGE, 2019). Segundo os dados do PEVS (2019) as florestas plantadas na região de estudo possuem uma área aproximada de 996.272 ha.

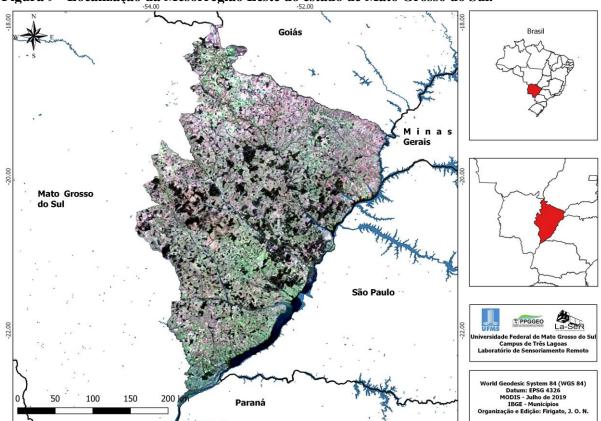


Figura 9 - Localização da Mesorregião Leste do estado de Mato Grosso do Sul.

## 4.2 Fluxograma

A partir da região de estudo definida, foi elaborado um fluxo de processos entre as plataformas utilizadas no estudo, aproveitando-se das suas principais características e da integração entre elas. O Google Earth Engine foi utilizado primeiro para a análise climática e espectral da região dentro no ano de 2019, depois para análise das áreas que foram amostradas, e por fim para a delimitação do "Ground Truth" e obtenção dos dados. O Google drive serviu de armazenamento desses dados e dos resultados gerados pelo treinamento do modelo no Google Colab. Após a obtenção do mapeamento, ele foi disponibilizado em um APP desenvolvido no Google Earth Engine.

A Figura 10 exibe um fluxograma com as principais etapas dos procedimentos metodológicos adotados.

Amostragem das regiões Exportação do modelo mosaico final do APP

Figura 10 - Fluxograma do processo metodológico.

Fonte: Autor

Os scripts tanto para obtenção dos dados no GEE quanto para criação do aplicativo e disponibilização do mapeamento foram gerados através da linguagem de programação Javascript. Já a construção e processamento da rede convolucional neural no Colab foi feito em Python utilizando a biblioteca Keras, além de outros pacotes auxiliares.

# 4.3 Análise climática e espectral da região de estudo

A Figura 11 demonstra a variação da precipitação média diária por mês para a região de estudo no ano de 2019, obtidas pelo dataset CHIRPS (FUNK et al., 2015), e da temperatura média diária para cada mês ano de 2019, obtida através do dataset ERAS5 (HERSBACH et al., 2018). A Figura 12 representa a variação da precipitação diária média por mês e a temperatura média diária por mês para o período dos últimos 20 anos.

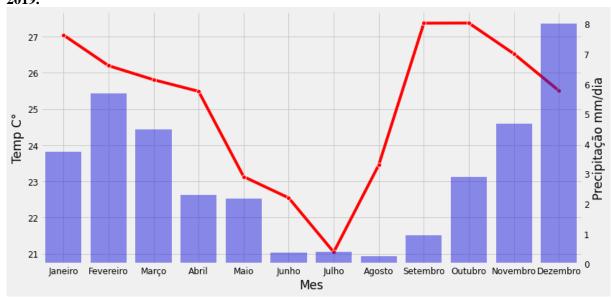
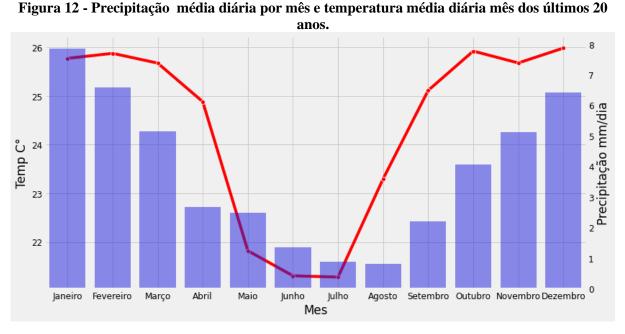


Figura 11 – Precipitação média diária por mês e temperatura média diária mês para o ano de 2019.

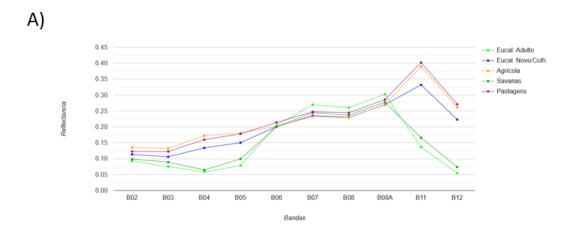


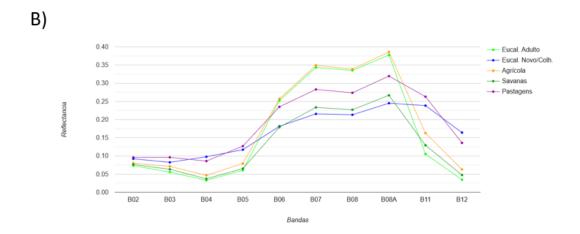
Fonte: Autor.

Para uma melhor compreensão do comportamento espectral das áreas de silvicultura e de outros tipos de cobertura presentes na área de estudo, foram analisados gráficos com os valores médios de reflectância TOA em relação as bandas selecionadas no estudo, para 2 períodos com variações climáticas diferentes onde foram possíveis a obtenção de mosaicos livres de nuvens.

A Figura 13 A representa os alvos no mês de setembro, final do período seco, onde foi observado uma grande semelhança espectral entre amostras de eucalipto adulto e amostras de savanas. Já amostras de áreas de eucalipto colhidos ou plantados recentemente, apresentam uma semelhança com amostras de pastagens e áreas agrícolas com o solo exposto.

Figura 13 - Curva espectral dos diferentes tipos de uso e cobertura no mês de setembro de 2019 (A) e no mês de maio de 2019 (B).



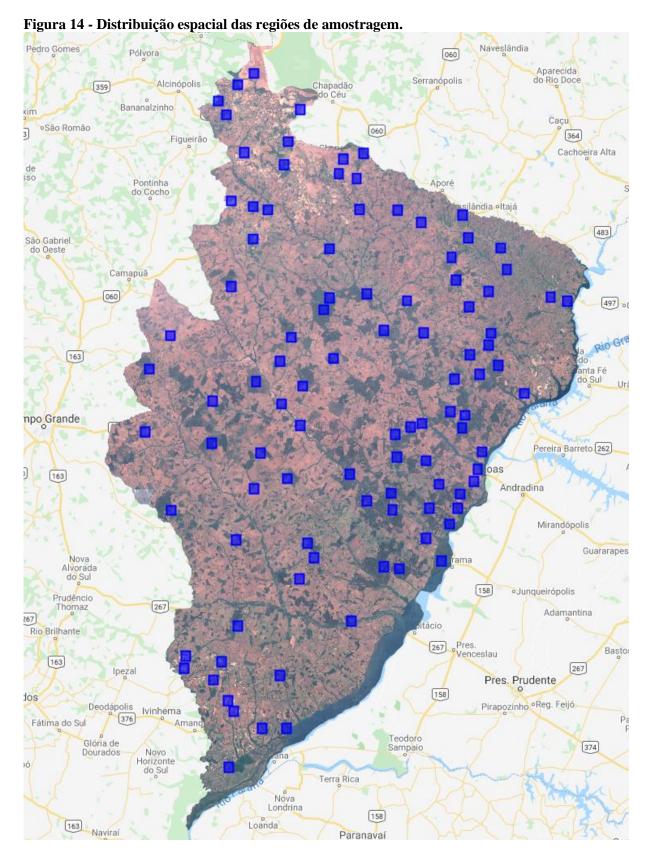


Fonte: Autor.

Já a Figura 13 B representa a curva espectral dos alvos no mês de maio, após o fim do período chuvoso na região, evidenciando a atuação da água nas curvas espectrais da vegetação, alterando os valores de reflectância, principalmente para as amostras de áreas que sofrem uma maior influência do umidade do solo, como as agrícolas, com pastagens e áreas de corte ou plantio recente de eucalipto.

# 4.4 Aquisição do dataset

Para a escolha das áreas onde foram coletadas as amostras, realizou-se uma análise prévia da região de estudo, compreendendo seus diferentes tipos de uso e cobertura da terra, as diferentes formas e estágios de talhões de eucalipto, afim de abranger uma amostragem mais homogênea possível. Assim, foram definidas 110 regiões de coleta conforme apresentado na Figura 14.



## 4.4.1 Definição das características espectrais, espaciais e temporais

As imagens das áreas selecionadas apresentam inicialmente dimensão fixa de 320x320 pixels. Para a dimensão espectral foram escolhidas as bandas do Satélite Sentinel 2A: B2, B3, B4, B5, B6, B7, B8, B8A, B11, e B12. Também foram adicionados os seguintes índices espectrais gerados por aritmética de bandas: NDVI, SAVI, EVI, NDWI, NDMI, NDRE e GVMI. Todas as bandas e índices foram redimensionadas para 20 metros de resolução espacial.

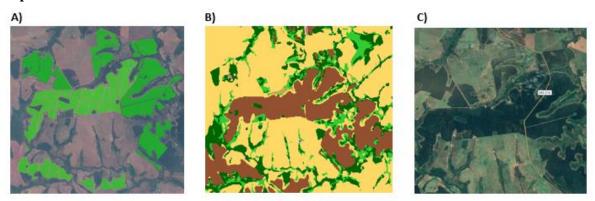
De acordo com a análise climática da área de estudo para o ano de 2019 foram escolhidos três épocas diferentes para realizar a coleta de imagens para cada uma das regiões de amostragem, aproveitando-se assim da variação espectral entre os diferentes períodos climáticos do ano. O primeiro período compreende o final da estação das chuvas no Leste do estado do Mato Grosso do Sul. Como a quantidade de nuvens neste período é alta, foi conseguido um mosaico limpo somente no mês de maio. O segundo período é o final da estação seca no Leste do estado do Mato Grosso do Sul. Assim, o final do mês de setembro foi o período onde o mosaico limpo de nuvens estava disponível. Também foi definido um terceiro período como intermediário entre os dois primeiros, compreendendo em datas do mês de julho.

Esta estratégia de mesclar imagens de diferentes períodos climáticos do ano visa dar uma maior robustez ao modelo, evitando que aprenda somente características espectrais de um período específico e falhe ao tentar predizer amostras durante outro períodos do ano. Além da robustez, essa estratégia proporciona alimentar o modelo com mais amostras sem a necessidade de coletar mais máscaras.

#### 4.4.2 Delimitação das áreas de silvicultura presente nas imagens

Para realização da etapa de rotulagem binária da imagem, o Google Earth Engine foi utilizado como a base para a delimitação dos polígonos tendo como referência imagens do satélite Sentinel 2 do ano de 2019. Em algumas regiões onde a distinção visual entre as classes ficou mais difícil, foi necessário o auxílio de imagens de alta resolução do Google Maps, ou a utilização do mapeamento de uso e cobertura da terra do Mapbiomas (Figura 15).

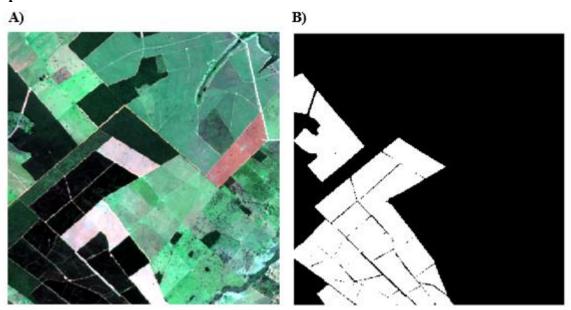
Figura 15 - Processo de geração dos polígonos delimitando regiões que contém silvicultura. A) Delimitação feita no Google Earth Engine. B) Validação visual pelo mapeamento de uso e cobertura de 2018 feito pelo Mapbiomas. C) Validação com imagem de alta resolução do Google Maps.



## 4.4.3 Exportação das máscaras e imagens para o Google Drive

Após a delimitação dos polígonos, realizou-se recorte das regiões amostradas e a criação das máscaras binárias com valores de 0 para não-silvicultura e 1 para pixels representando silvicultura (Figura 16). Foram coletados uma porcentagem de 78,26% de pixels com áreas de não eucalipto e 21,84% de áreas de eucalipto. Em seguida as imagens e máscaras foram exportadas para o armazenamento em nuvem no Google Drive.

Figura 16 - Exemplo de amostra coletada. A) imagem RGB do satélite Sentinel 2. B) máscara representando áreas de silvicultura.



## 4.5 Treinamento do modelo de segmentação semântica

O processo de segmentação semântica foi particionado em etapas, onde primeiro as imagens e máscaras rotuladas foram processadas e separadas em dados de treinamento, validação e de testes, alimentando a arquitetura definida. Para o treinamento do modelo foi utilizado a GPU NVIDIA TESLA K80 na plataforma Google Colab. Após a finalização do treinamento e estabilização das métricas de validação, o modelo final foi obtido para predição do mapa da área de estudo.

#### 4.5.1 Preparação do dataset

Esta etapa consistiu na importação das imagens e máscaras rotuladas do Google Drive para o Google Colab, onde foram convertidas em matrizes de números digitais em um intervalo de valores entre 0 e 1. Também foi realizada a divisão da imagem de 320 x 320 pixels em 4 imagens de 160 x 160 pixels, diminuindo o tamanho dos dados que alimentarão a rede neural e aumentando a quantidade de exemplos. A separação de amostras em treino, validação e testes foi realizada aleatoriamente por região de amostragem. Sendo assim, das 110 regiões, 80 foram separadas para o treinamento, 15 para validação e 15 para teste. Considerando que para cada região foi dividida em 4 imagens e para cada divisão foi obtida 3 imagens de períodos diferentes, a quantidade de amostras para treinamento foi de 960, 180 para validação e 180 para teste.

Como apresentado anteriormente, as redes neurais necessitam de uma grande quantidade de dados para aprender as principais características do conjunto. No entanto a delimitação manual de grandes quantidades de amostras para a segmentação semântica tem um enorme custo de tempo, sendo assim muito útil a técnica de aumento de dados. Esta técnica consiste em operações espaciais nas imagens de satélite e nas máscaras rotuladas, como rotações, giros, deslocamentos e ampliações a fim de se obter mais amostras sintéticas para alimentar a rede adicionando robustez à rede e diminuindo o overfitting (Chhor e Aramburu, 2017). Por essas vantagens o uso do aumento de dados de treinamento na segmentação semântica de imagens de satélite tornou-se muito comum como em Saraiva et al. (2020) e Chen et al. (2020).

## 4.5.2 Definição da arquitetura da rede neural

Conforme apresentado anteriormente a estrutura de uma rede neural é composta por diversas camadas, sendo que a primeira camada recebe os dados de entrada, seguindo por uma ou mais camadas ocultas que extraem os mapas de características, e por último a camada de saída, que retorna o resultado da rede (REIS, 2018). A quantidade de camadas, a disposição dessas camadas e as operações que essas camadas realizam, definem para qual tarefa a rede foi denominada e o quão bem a rede consegue representar os dados e gerar bons resultados.

Deste modo, após uma análise prévia de algumas arquiteturas, foi definida a utilização da U-net por se destacar em diversos trabalhos anteriormente apresentados, que se baseia em uma estrutura codificadora e uma estrutura decodificadora (YOSHIHARA, 2018). No codificador foi utilizado a base de uma ResNet de 101 camadas com algumas modificações referentes ao ajuste fino, que buscou obter resultados que convergiram para o propósito do trabalho (Figura 17). Para o decodificador foi utilizado uma arquitetura padrão da U-net.

Conv Block Resnet 101-layer Resnet Modificada Input (160 x160) Input (160 x160) В Conv 1x1 Conv 1x1 Conv 7x7, stride 2 Conv 3x3 Conv 1x1 Conv block 2x **Identity** block **Identity Block** Conv block dentity block ▼ **Identity** block Conv block 3x **Identity** block Conv 1x1 Conv block Conv block Conv 3x3 23x **Identity** block 23x Identity block Conv 1x1 Add **Identity block** ldentity block

Figura 17 - Comparativo entre a arquitetura resnet 101 e a modificação utilizada no codificador.

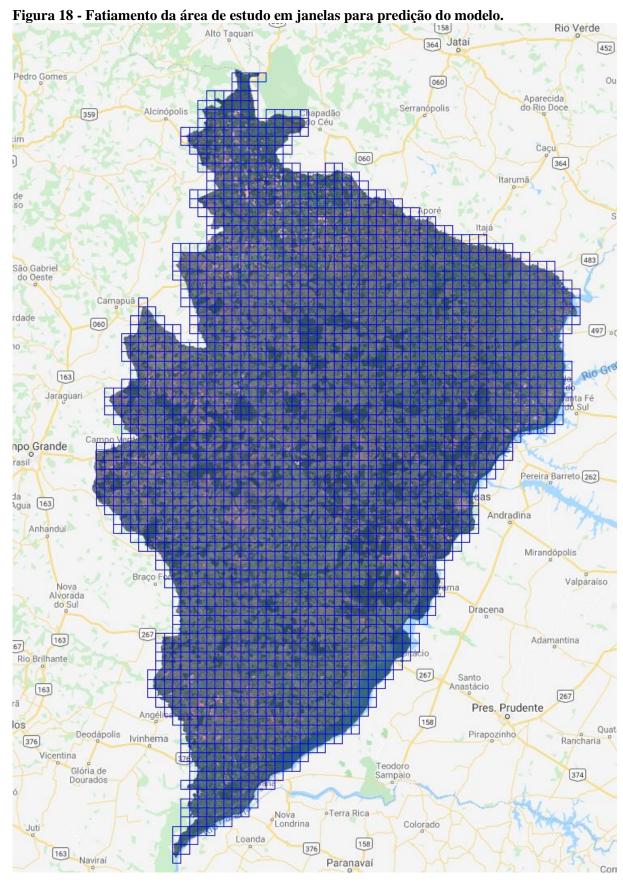
#### 4.5.3 Treinamento da rede neural

Definida a configuração da rede para a tarefa de segmentação semântica, o próximo passo foi a realização do treinamento da rede neural convolucional. No processo de treinamento os três principais hiperparâmetros definidos foram o tamanho do lote, os passos por épocas e a quantidade de épocas. O tamanho do lote é a quantidade de imagens utilizadas para treinamento em uma única época. Esse tamanho foi ajustado de acordo com a quantidade de memória disponível da GPU, ficando assim definido com um valor 16. Os passos por épocas são a quantidades de vezes em uma época em que será utilizada alguma das imagens disponíveis no lote de treinamento. Já a quantidade de épocas é o número de iterações que a rede neural irá realizar. Deste modo foi definido 16 passos por época e aproximadamente 10000 épocas de treinamento.

Após o treinamento do modelo finalizado, as métricas de validação apresentadas anteriormente foram utilizadas para avaliar os resultados. Neste primeiro momento, foi verificado se o modelo estava apresentando possíveis problemas de underfitting (quando o modelo apresenta baixa performance para os dados de treinamento) e o overfitting (quando o modelo apresenta altos resultados para os dados de treinamento mas não tem uma boa performance para os dados de teste).

## 4.6 Obtenção do mapeamento

Para a obtenção do mapeamento de áreas de silvicultura na mesorregião leste do estado do Mato Grosso do Sul para os anos pré-definidos foi necessário a utilização do modelo treinado para predizer toda a área delimitada pela região de estudo. Desta maneira foi gerado um mosaico da mediana das cenas sem nuvens da região de estudo no Google Earth Engine. O período de datas selecionado para geração do mosaico foi o que melhor se apresentou em relação as métricas de validação do dataset de teste. Realizou-se então o download desse mosaico com as bandas e índices utilizados no treinamento e por fim foi dividido em janelas (Figura 18) de 160 x 160 pixels para a compatibilidade com o modelo gerado. Assim foi possível a predição de cada uma dessas janelas e realizado a junção de todas em um único arquivo raster, representando a região de estudo.



# 5 RESULTADOS E DISCUSSÃO

Para uma melhor análise, os resultados foram divididos em quatro seções: a primeira composta pelo uso das métricas de validação sobre os resultados gerais do modelo para o conjunto de treinamento e para o conjunto de teste, a segunda seção avalia o conjunto de teste de acordo com divisão por períodos definidos anteriormente, a terceira seção avalia por amostra do conjunto de teste, e a quarta seção demostra os resultados dos mapeamentos obtidos para cada ano proposto.

#### 5.1 Resultados gerais

De acordo com a Tabela 2, no conjunto de treinamento o modelo obteve uma acurácia global de 98,98%, uma precisão de 98,36%, recall de 98,85%, índice jaccard de 0,979 e um índice kappa de 0,972. Para o conjunto de validação o modelo obteve uma acurácia global de 98,68%, uma precisão de 97,43%, recall de 96,85%, índice jaccard de 0,973 e índice kappa de 0,942. Por fim, no conjunto de teste, foi obtido uma acurácia global de 98,24%, uma precisão de 97,12%, recall de 97,30%, índice de jaccard de 0,965 e um índice kappa de 0,944.

Tabela 2. Métricas de validação por dataset.

Dataset	Métricas						
	Acurácia Global	Precisão	Recall	Jaccard	Kappa		
Treino	98,98%	98,36%	98,85%	0,979	0,972		
Validação	98,68%	97,43%	96,85%	0,973	0,942		
Teste	98,24%	97,12%	97,30%	0,965	0,944		

A matriz de confusão dos resultados de treinamento (Figura 19), validação (Figura 20) e dos resultados de testes (Figura 21) foram geradas por quantidade de pixels e por percentual.

Figura 19 - Matriz de Confusão dos resultados do conjunto de treinamento.

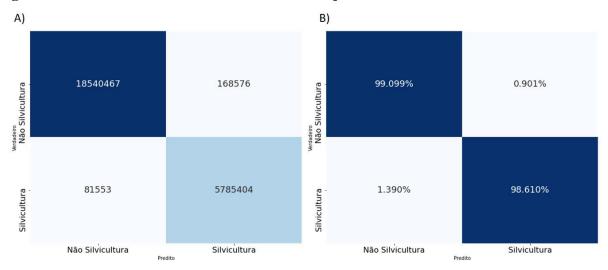
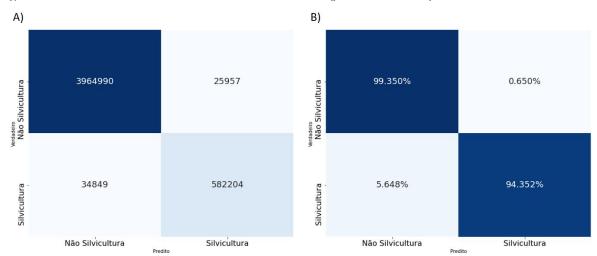


Figura 20 - Matriz de Confusão dos resultados do conjunto de validação.



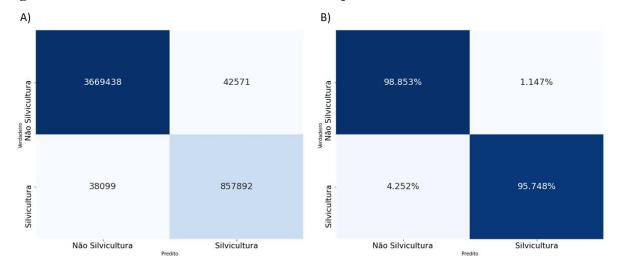


Figura 21 - Matriz de Confusão dos resultados do conjunto de teste.

#### 5.2 Resultados de validação por período

Como as amostras foram coletadas em três períodos específicos que contém uma variação espectral, é interessante a verificação das métricas de validação por cada período, observando assim em qual período foi obtido os melhores resultados.

A Tabela 3 faz um comparativo entre as métricas de validação utilizadas no dataset de teste para os períodos propostos. No período úmido foi obtida uma acurácia global de 98,46%, uma precisão de 97,50%, recall de 97,58%, índice de jaccard de 0,969 e índice kappa de 0,950. No período intermediário foi obtida uma acurácia global de 98,50%, uma precisão de 97,73%, recall de 97,50%, índice de jaccard de 0,970 e índice kappa de 0,952. Por fim, no período seco a acurácia global foi de 97,78%, uma precisão de 96,15%, recall de 96,81%, o índice de jaccard de 0,956 e o índice kappa de 0,929.

Tabela 3. Métricas de validação para os períodos climáticos.

Período	Métricas					
	Acurácia Global	Precisão	Recall	Jaccard	Kappa	
Úmido	98,46%	97,50%	97,58%	0,969	0,95	
Intermediário	98,50%	97,73%	97,50%	0,97	0,952	
Seco	97,78%	96,15%	96,81%	0,956	0,929	

As métricas de validação também foram utilizadas para verificar a coerência entre os períodos (Tabela 4), ou seja o quanto os resultados são semelhantes. A semelhança entre os períodos úmido e seco, obteve uma acurácia de 97,94%, índice de jaccard de 0,959 e índice

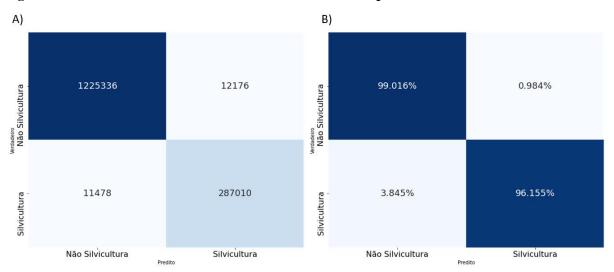
kappa de 0,934. Entre o período seco e intermediário a acurácia foi de 98,11%, índice de jaccard de 0,962 e índice kappa de 0,940. Para a relação entre o período úmido e intermediário, a acurácia foi de 99,16%, índice de jaccard de 0,983 e índice kappa de 0,973.

Tabela 4. Comparação das métricas de validação entre os resultados por período climático.

Período	Métricas				
	Acurácia Global	Jaccard	Kappa		
Úmido X Seco	97,94%	0,959	0,934		
Intermediário X Seco	98,11%	0,962	0,940		
Úmido X Intermediário	99,16%	0,983	0,973		

O uso da matriz de confusão demonstra a quantidade de pixels e a porcentagem classificados corretamente, possibilitando um avaliação de cada período com informações mais expressivas sendo demonstradas pelas figuras 22, 23 e 24.

Figura 22 - Matriz de Confusão das amostras referentes ao período úmido.



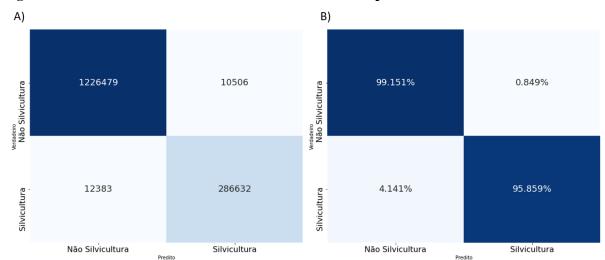


Figura 23 - Matriz de Confusão das amostras referentes ao período intermediário.

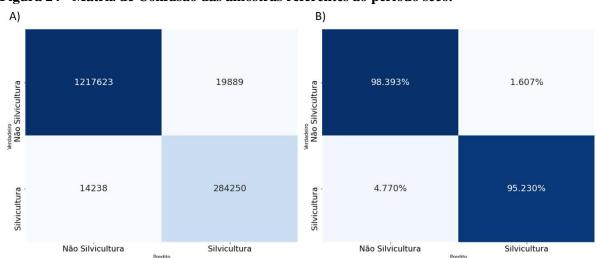


Figura 24 - Matriz de Confusão das amostras referentes ao período seco.

# 5.3 Resultados de validação por amostras

A última etapa de avaliação dos resultado foi a validação por amostras, onde a Tabela 3 demonstra os valores da acurácia global e índice de Jaccard para as 60 amostras do conjunto de teste nos três períodos definidos.

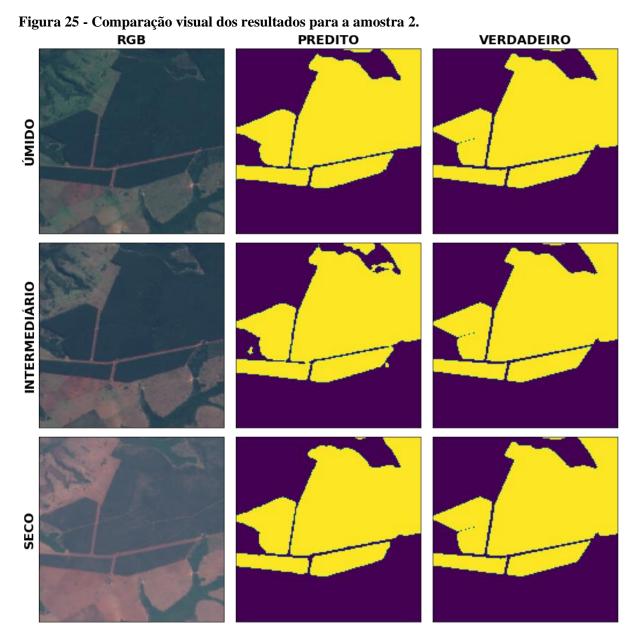
Tabela 5. Resultados por amostra.

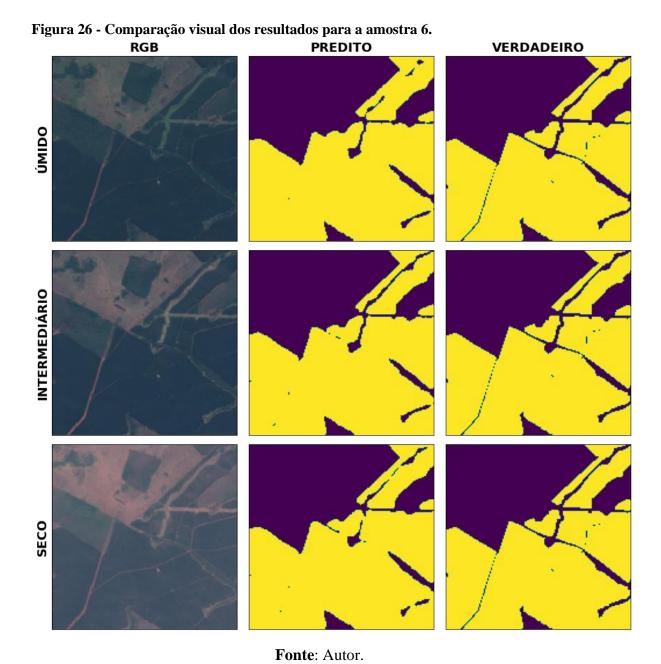
Amostra	Tabela 5. Resultados por amostra.  Métricas						
Amostra	Úmido		Intermediário Seco				
	Acurácia Global	Jaccard	Acurácia Global	Jaccard	Acurácia Global	Jaccard	
1	100.0%	1	100.0%	1	100.0%	1	
2	98.74%	0,975	97.77%	0,956	98.65%	0,973	
3	100.0%	1	100.0%	1	100.0%	1	
4	99.82%	0,996	100.0%	1	99.98%	1	
5	99.99%	1	99.99%	1	67.53%	0,51	
6	97.8%	0,957	98.34%	0,967	98.12%	0,963	
7	96.99%	0,942	97.71%	0,955	97.39%	0,949	
8	99.66%	0,993	99.71%	0,994	99.56%	0,991	
9	98.46%	0,97	98.66%	0,973	98.67%	0,974	
10	95.98%	0,923	97.65%	0,954	97.73%	0,956	
11	100.0%	1	100.0%	1	100.0%	1	
12	99.98%	1	99.79%	0,996	99.99%	1	
13	100.0%	1	100.0%	1	100.0%	1	
14	93.93%	0,886	93.92%	0,885	99.69%	0,994	
15	100.0%	1	100.0%	1	100.0%	1	
16	99.91%	0,998	99.86%	0,997	100.0%	1	
17	99.64%	0,993	99.59%	0,992	99.64%	0,993	
18	99.91%	0,998	100.0%	1	100.0%	1	
19	100.0%	1	100.0%	1	99.86%	0,997	
20	100.0%	1	100.0%	1	100.0%	1	
21	98.46%	0,97	99.16%	0,983	98.99%	0,98	
22	100.0%	1	100.0%	1	99.87%	0,997	
23	100.0%	1	100.0%	1	100.0%	1	
24	100.0%	1	100.0%	1	100.0%	1	
25	98.89%	0,978	98.91%	0,978	99.05%	0,981	
26	95.51%	0,914	90.36%	0,824	95.52%	0,914	
27	100.0%	1	100.0%	1	100.0%	1	
28	97.41%	0,95	96.95%	0,941	98.54%	0,971	
29	100.0%	1	100.0%	1	100.0%	1	
30	99.74%	0,995	99.33%	0,987	99.28%	0,986	
31	95.84%	0,92	98.5%	0,971	97.66%	0,954	
32	97.86%	0,958	97.17%	0,945	97.68%	0,955	
33	86.82%	0,767	89.39%	0,808	85.56%	0,748	
34	96.6%	0,934	95.98%	0,923	95.31%	0,91	
35	100.0%	1	100.0%	1	100.0%	1	
36	96.74%	0,937	96.78%	0,938	96.65%	0,935	
37	86.72%	0,766	85.23%	0,743	84.46%	0,731	
38	99.29%	0,986	99.19%	0,984	99.68%	0,994	
39	100.0%	1	100.0%	1	100.0%	1	

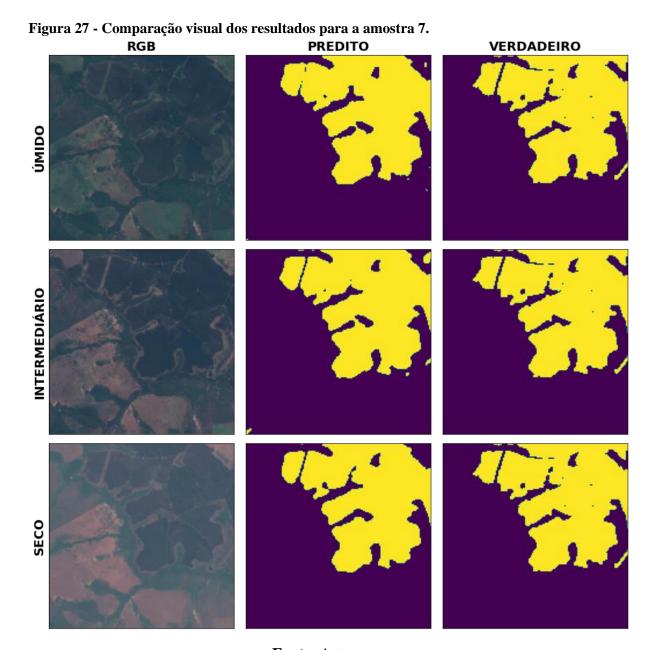
40	100.0%	1	100.0%	1	100.0%	1
41	100.0%	1	100.0%	1	100.0%	1
42	100.0%	1	100.0%	1	100.0%	1
43	97.91%	0,959	98.0%	0,961	96.86%	0,939
44	99.6%	0,992	99.69%	0,994	99.75%	0,995
45	95.2%	0,908	96.66%	0,935	89.22%	0,805
46	100.0%	1	100.0%	1	100.0%	1
47	98.41%	0,969	98.61%	0,973	98.62%	0,973
48	100.0%	1	100.0%	1	100.0%	1
49	100.0%	1	100.0%	1	100.0%	1
50	99.97%	0,999	100.0%	1	99.88%	0,998
51	99.23%	0,985	100.0%	1	100.0%	1
52	97.79%	0,957	98.25%	0,966	97.99%	0,961
53	94.91%	0,903	94.99%	0,905	94.34%	0,893
54	97.56%	0,952	97.32%	0,948	98.21%	0,965
55	100.0%	1	100.0%	1	100.0%	1
56	99.12%	0,983	99.54%	0,991	99.0%	0,98
57	97.65%	0,954	97.92%	0,959	91.66%	0,846
58	100.0%	1	100.0%	1	100.0%	1
59	100.0%	1	100.0%	1	100.0%	1
60	99.52%	0,991	99.69%	0,994	96.11%	0,925

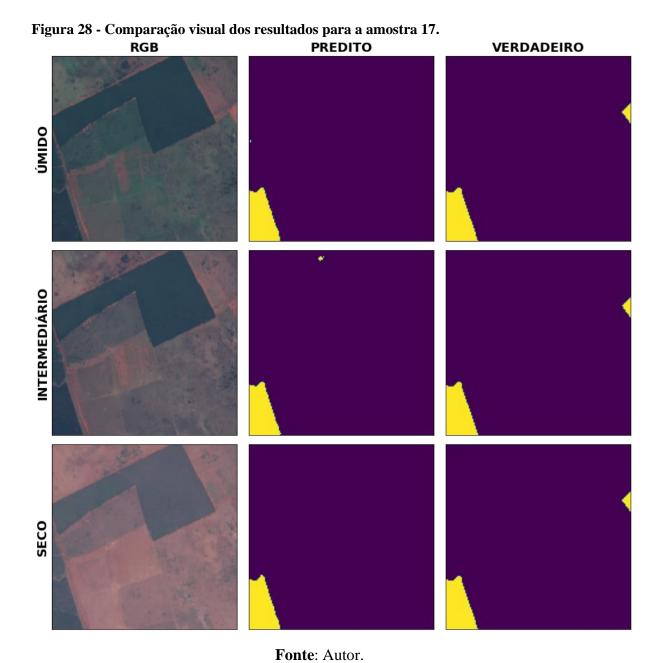
De acordo com os resultados, a maioria das amostras apresentaram valores de acurácia global entre 97% e 100%, e índice de jaccard acima de 0,95 para os três períodos. As amostras 14, 26, 34, 37, 45 e 53, obtiveram valores abaixo da média da acurácia global e do índice de jaccard do dataset.

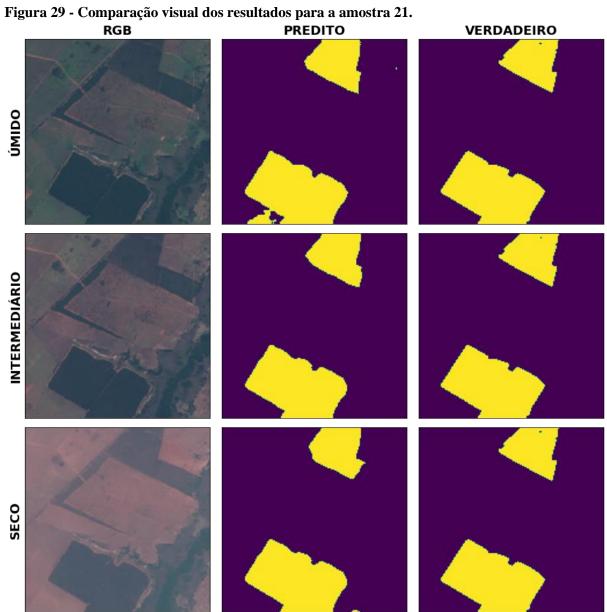
As Figuras 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35 e 36 representam o comparativo visual entre a imagem em cor verdadeira, o resultado predito e o esperado para os três períodos propostos das amostras 2, 6, 7, 17, 21, 26, 34, 38, 43, 48, 53, 60.

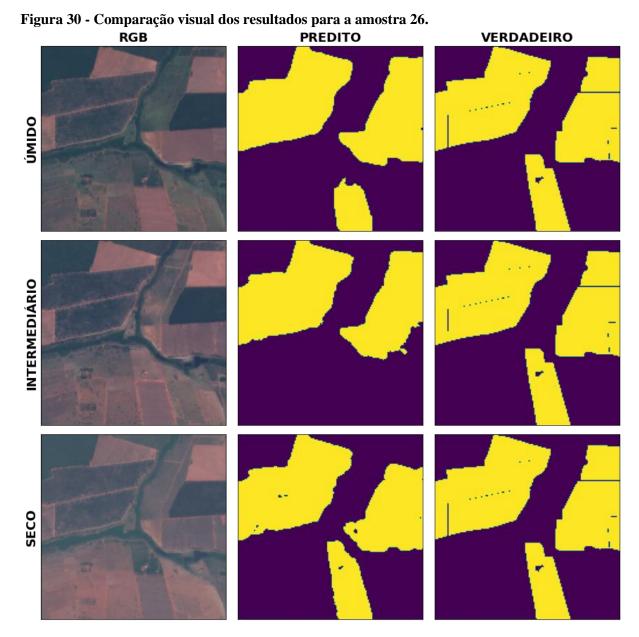


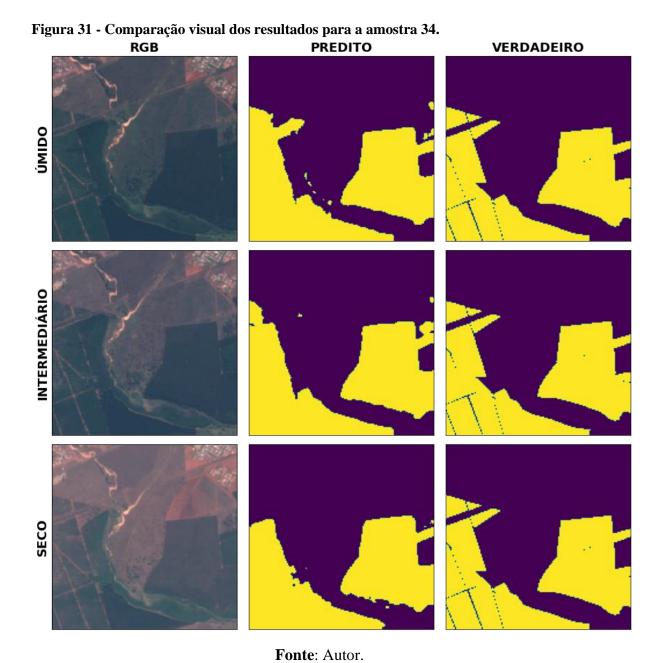


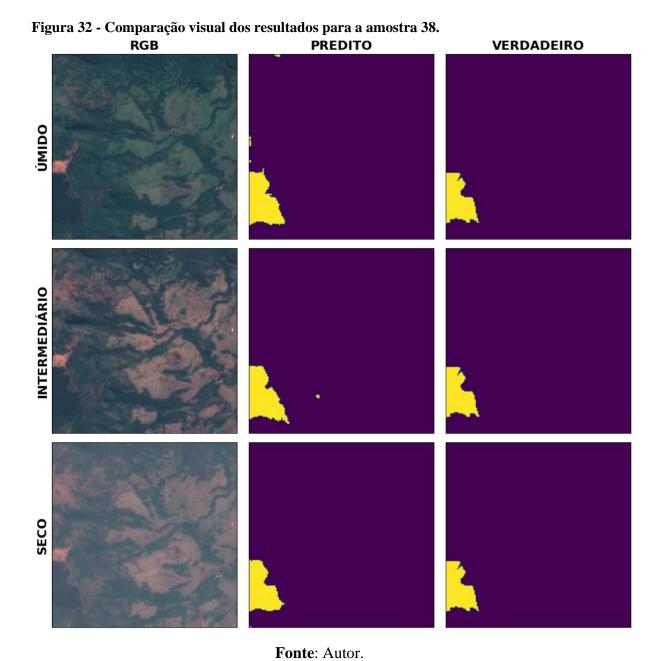


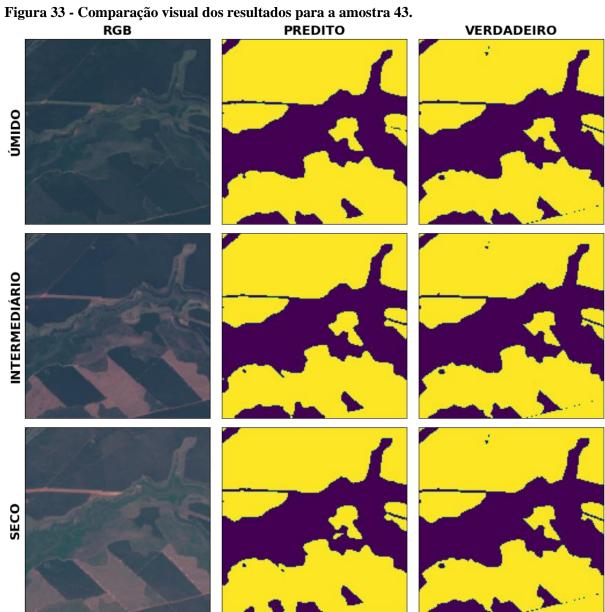


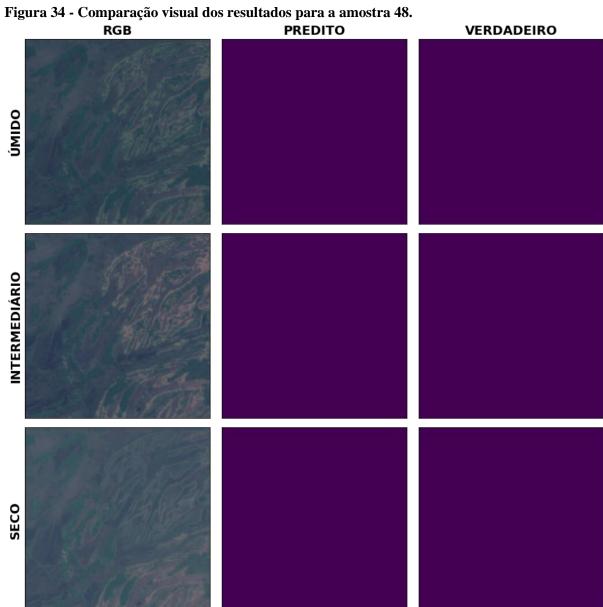


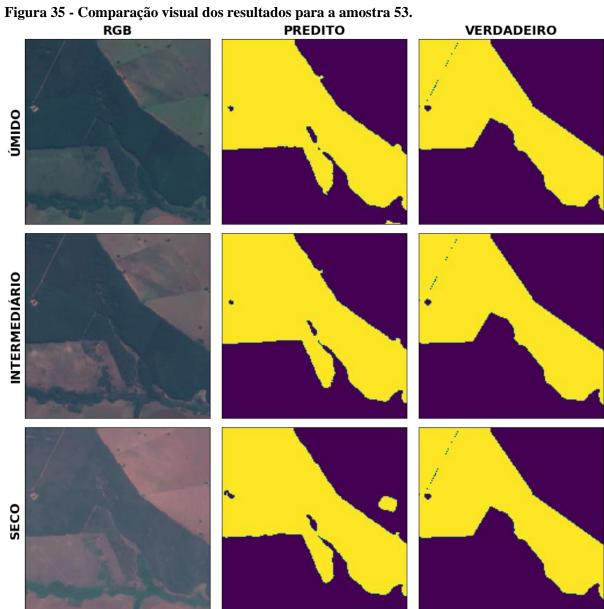












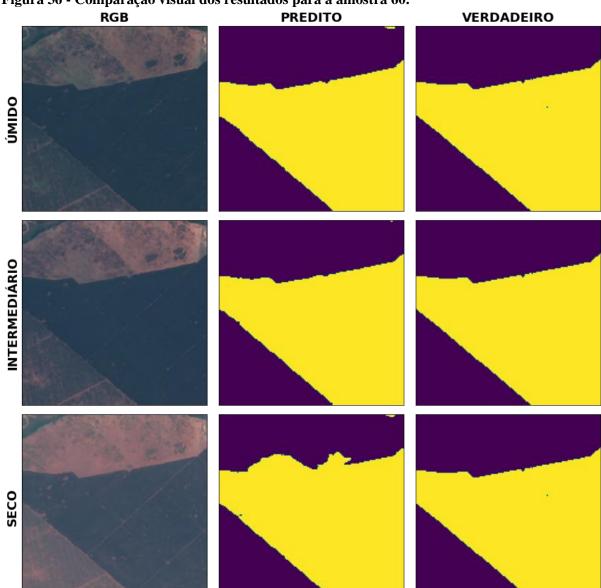


Figura 36 - Comparação visual dos resultados para a amostra 60.

Fonte: Autor.

## 5.4 Resultados dos mapeamentos

Após a obtenção dos resultados quantitativos em relação as métricas de avaliação, também foi possível obter a partir dos mosaicos preditos, a área anual mapeada de silvicultura entre 2017 e 2020. Conforme a Figura 37, a área total de silvicultura mapeada para a região de estudo no ano de 2017 foi de 8.149 km², representando 8,6% da área total. Para o ano de 2018 as áreas de silvicultura sofreram uma queda de 7% em relação ao ano anterior, obtendo um total de 7.569 km², que representa 8% da área total. No ano de 2019 as áreas de silvicultura obtiveram um acréscimo de 23% em relação ao ano de 2018, alcançando uma área estimada

de 9.341 km², ou 9,7% da área total. Em 2020, houve uma diminuição de 3,5% em relação à 2019 representando 9,5% da área total da mesorregião leste, com uma área de 9.010 km².

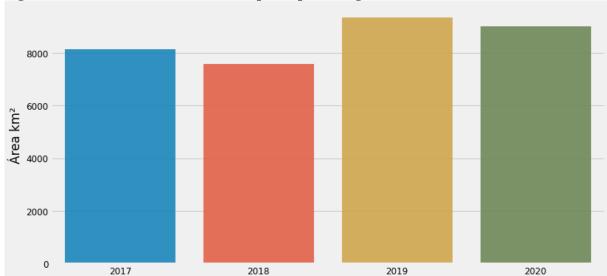


Figura 37 - Área total de silvicultura mapeada para a região de estudo.

Fonte: Autor.

A Figura 38 mostra a quantidade de áreas novas incorporadas pela silvicultura na região em relação aos anos selecionados para o estudo sem descontar as áreas perdidas. O ano de 2017 foi selecionado como ano base, com uma área de 8.149 km². Para 2018, 241 km² foram incorporados nas áreas de silvicultura. Em 2019, houve um acréscimo de 1.801 km², e em 2020, 605 km² foram adicionados à silvicultura.

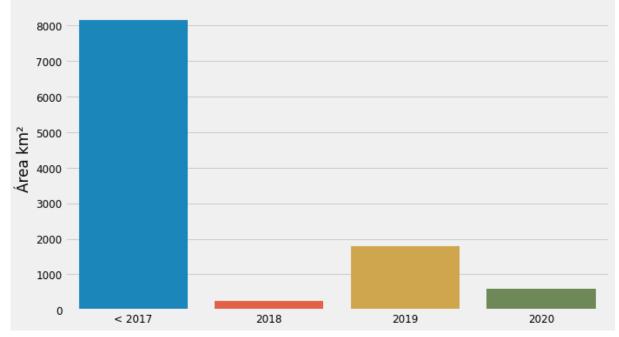


Figura 38 - Quantidade de áreas incorporadas pela silvicultura sem descontar as perdas.

## 5.4.1 Disponibilização do mapeamento pelo Google Earth Engine Apps

O Google Earth Engine também permite a disponibilização de resultados de análise de uma forma interativa, sendo possível implementar diversas funções que auxiliam na interação entre os usuários e a informação disponibilizada. O ForestryViewApp foi implementado para disponibilizar o mapeamento obtido pelo modelo de segmentação semântica, sendo possível a utilização desse modelo para gerar resultados de mapeamentos para anos anteriores e posteriores, de acordo com a disponibilidade de imagens do satélite Sentinel 2.

Assim, através do link https://forestryviewapp.users.earthengine.app/view/forestryviewapp é possível acessar o mapeamento (Figura 39).

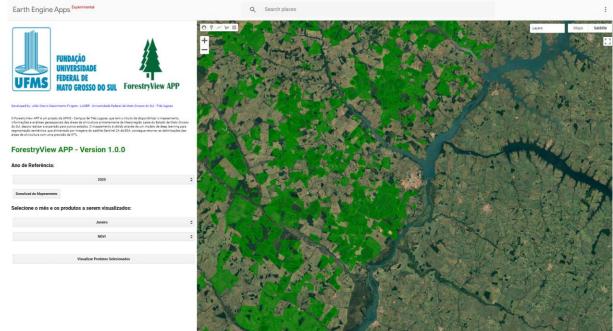


Figura 39 - Apresentação visual do ForestryView App.

Fonte: Autor.

Além dos mapeamentos para cada ano pré-definido, também é disponibilizado informações mensais de alguns índices espectrais como o NDVI (Figura 40), EVI, SAVI e o NDMI. Também foi adicionado o Global Forest Canopy Height (POTAPOV et al., 2020) para o ano de 2019, possibilitando a visualização da estimativa de altura das florestas plantadas (Figura 41). Outra informação adicionada é o mapa de ganhos de área anuais da silvicultura, conforme a Figura 42.

FUNDAÇÃO
UFFINS

FUNDAÇÃO
UFFINS

FUNDAÇÃO
UFFINS

FORESTONIE

FORESTONIE

FORESTONIE

FORESTONIE

FORESTONIE

AND

TO PORT ME TO THE PROPRIED TO THE PROPRIED

Figura 40 - NDVI mensal das áreas de silvicultura.

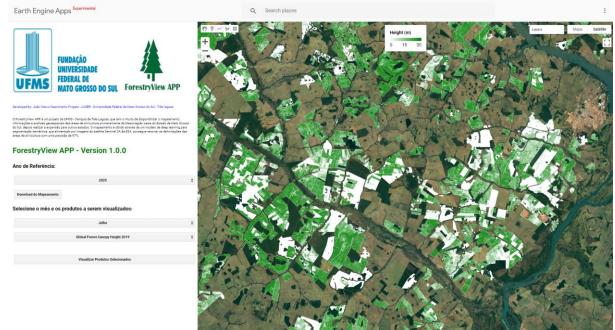


Figura 41 - Estimativa de altura de árvores nas áreas de florestas plantadas para o ano de 2019.

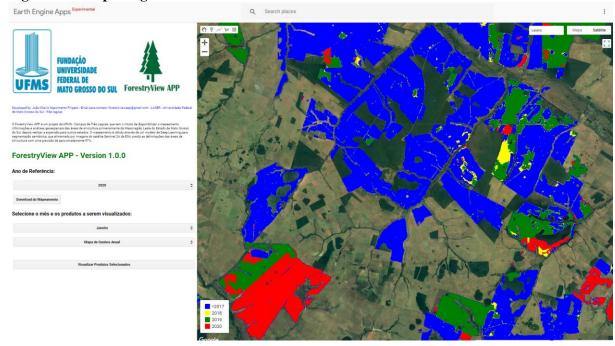


Figura 42 - Mapa de ganhos de áreas de silvicultura anual.

Fonte: Autor.

#### 5.5 Discussão

Os resultados deste trabalho demonstraram a viabilidade do uso da segmentação semântica com redes neurais convolucionais para a identificação de áreas de silvicultura na região de estudo. O modelo resultante obteve uma acurácia global de 98,24% e um índice de similaridade de jaccard de 0,947 nos dados de teste. Quando comparado o dataset de teste com a classe de florestas plantadas obtida no mapeamento de uso e cobertura realizado pelo Mapbiomas para o ano de 2019, a acurácia global obtida foi de 96,16% e o índice de similaridade de jaccard de 0,926. Alguns outros estudos também conseguiram alcançar bons resultados como em Forstmaier et al. (2020), onde obtiveram uma acurácia global de 92,5% para o mapeamento de *Eucalyptus* em Portugal com imagens do satélite Sentinel 2, utilizando-se de uma rede neural *feedforward* para a classificação, diferentemente deste trabalho. Em Le Marie et al. (2014) foi realizado o mapeamento de florestas plantadas utilizando-se series temporais do NDVI obtidas do sensor MODIS, obtendo também bons resultados, mas com uma resolução espacial menor que a do satélite Sentinel 2.

Já na separação dos dados de teste em três períodos, o período intermediário (Julho/2019) obteve valores mais altos das métricas de validação, seguido do período úmido (Maio/2019) e do período seco (Setembro/2019). Também foi avaliada a similaridade dos

resultados entre os períodos, sendo que a relação entre o úmido e o intermediário foi a mais similar.

Mesmo com uma alta acurácia, alguns problemas como por exemplo os falsos positivos ocorrem em algumas regiões das imagens preditas. Outro problema que atinge o modelo é a diferença nos resultados de acurácia e na semelhança entre as predições dos três períodos dentro de um mesmo ano de referência e entre os mapeamentos anuais preditos.

A área total mapeada para o ano de 2019 foi de 9.341 km², ficando próximo dos dados do levantamento do PEVS para o ano de 2019, onde foram obtidos 9.962 km². Por outro lado em comparação ao Mapbiomas, apresentou divergências nos resultados, visto que a área obtida foi de 7.892 km². Para os anos de 2017 e 2018 também houve uma área maior obtida em relação ao Mapbiomas. Em 2017 foi obtida uma área de 8.149 km² contra 7.415km². No ano de 2018, foi obtida uma área de 7.569 km² contra 7.042 km². Tanto as metodologias utilizadas quanto as diferentes resoluções espaciais (20m contra 30m do Mapbiomas), podem ocasionar as diferenças na precisão e nas áreas obtidas pelos mapeamentos.

Além disso, os resultados obtidos apresentam que de 2017 para 2018 houve uma pequena redução de 580 km² nas áreas de silvicultura. Para 2019, houve um aumento de 1.772 km² em relação à 2018. Já em 2020 ocorreu um decréscimo de 331 km² em relação à 2019.

A técnica de segmentação semântica em imagens de satélites tem sido utilizada em diversos trabalhos para a identificação e delimitação de alvos e objetos em que somente as características espectrais obtidas pelas imagens de satélite, não possibilitariam sua delimitação precisa, como por exemplo em Saraiva et al. (2020), que utilizou-se da arquitetura U-net para mapeamento de pivôs de irrigação. Em Henry et al. (2018), as redes neurais convolucionais foram utilizadas para detecção de estradas em imagens de SAR, assim como em Krestenitis et al. (2019), que segmentou áreas de derramamento de óleo em imagens SAR. Por fim Chhor e Aramburu (2017), obtiveram uma acurácia global de 95% na detecção de área construída em imagens de satélite, apresentando ótimos resultados com o uso desta técnica.

Apesar dos avanços, esta é uma técnica recente e em constante evolução, sendo preciso uma análise prévia de seu custo benefício, considerando fatores como o tamanho da área de estudo, as características do alvo, o tempo de vida que o modelo treinado terá, a acurácia global e visual necessária, o tempo de coleta de amostras e o tempo e custo de processamento. Assim, o tamanho da área de estudo, as características do alvo e a possibilidade do acesso à grande quantidade de dados e alto poder de processamento, contribuíram para a sua utilização, resultando em ótimos resultados.

# 6 CONSIDERAÇÕES FINAIS

Este trabalho utiliza-se de ferramentas como plataformas de computação em nuvem e algoritmos de aprendizado profundo para a criação de um aplicativo interativo de mapeamento e monitoramento de áreas de silvicultura presentes na mesorregião leste de Mato Grosso do Sul. O modelo de segmentação semântica gerado a partir do treinamento de uma rede neural convolucional obteve uma acurácia global de 98% na predição de áreas de silvicultura em imagens obtidas pelo satélite Sentinel 2A. A partir desse modelo, os mapeamentos dos anos de 2017, 2018, 2019 e 2020 foram obtidos e disponibilizados junto com outros produtos destinados ao monitoramento como índices espectrais de vegetação, estimativa de altura das árvores, focos de incêndios, mapa de ganhos de área de silvicultura e área total anual por município da mesorregião.

Trabalhos futuros podem explorar a utilização de outras arquiteturas de redes neurais convolucionais como o Deeplabv3+ ou a HRNet, a utilização de dados de outros satélites e sensores ou até mesmo outras informações geoespaciais, buscando uma melhoria na acurácia dos resultados. Para o ForestryViewAPP, diversos outros tipos de dados disponíveis no catálogo do Google Earth Engine podem ser adicionados aumentando a abrangência de informações do aplicativo.

Desta maneira o livre acesso as informações de mapeamento e monitoramento de áreas de silvicultura, torna-se um ganho importante para o planejamento ambiental e econômico da região, permitindo um olhar analítico para o uso tanto de instituições públicas como de instituições privadas.

# 7 REFERÊNCIAS BIBLIOGRÁFICAS

AMANI, M.; GHORBANIAN, A.; AHMADI, S. A.; KAKOOEI, M.; MOGHIMI, A.; MIRMAZLOUMI, S. M.; ALIZADEH MOGHADDAM, S.; MAHDAVI, S.; GHAHREMANLOO, M.; PARSIAN, S.; WU, Q.; BRISCO, B. Google Earth Engine Cloud Computing Platform for Remote Sensing Big Data Applications: A Comprehensive Review. IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing. 13. 5326-5350. 10.1109/JSTARS.2020.3021052. 2020.

BARNES, E. M.; CLARKE, T.R.; RICHARDS, S.E.; COLAIZZI, P.; HABERLAND, J.; KOSTRZEWSKI, M.; WALLER, P.; CHOI, C.; RILEY, E. THOMPSON, T.L. Coincident detection of crop water stress, nitrogen status and canopy density using ground-based multispectral data. In: INTERNATIONAL CONFERENCE ON PRECISION AGRICULTURE, 2000, Bloomington. Madison: ASA: CSSA: SSSA, 2000.

BEZERRA, Cides. Uma Abordagem de Segmentação Semântica de Íris para Fins Biométricos Usando Aprendizagem Profunda. Dissertação de Mestrado — Universidade Federal do Paraná. 2018.

CAMPS-VALLS, G. Machine Learning in Remote Sensing Data Processing. Machine Learning for Signal Processing XIX - Proceedings of the 2009 IEEE Signal Processing Society Workshop, MLSP 2009. 10.1109/MLSP.2009.5306233. 2009.

CAO, K.; ZHANG, X. **An Improved Res-UNet Model for Tree Species Classification Using Airborne High-Resolution Images**. *Remote Sens.* 2020, *12*, 1128. https://doi.org/10.3390/rs12071128.

CARREIRA, Rafael Marlon Pereira Costa Baeta. **Geographical Mapping Of Coffee Crops By Using Convolutional Networks**. Dissertação de Mestrado — Universidade Federal de Minas Gerais, Belo Horizonte, 2017.

CECCATO, P.; GOBRON, N.; FLASSE, S.; PINTY, B.; TARANTOLA, S. **Designing a spectral index to estimate vegetation water content from remote sensing data: Part 1: Theoretical approach. Remote Sensing of Environment**. 82(2-3), 2002. pp:188-197. doi:10.1016/S0034-4257(02)00037-8.

CHEN, L.; TAN, C.; PAN, Z.; XING, H.; YUAN, F.; ZHANG, P. A New Framework for Automatic Airports Extraction from SAR Images Using Multi-Level Dual Attention Mechanism. Remote Sensing. 12. 560. 10.3390/rs12030560. 2020.

CHEN, X.; LIN, X. **Big Data Deep Learning: Challenges and Perspectives**. Access, IEEE. 2. 514-525. 10.1109/ACCESS.2014.2325029. 2014.

CHHOR, G.; ARAMBURU, C. B.; Satellite Image Segmentation for Building Detection using U-net. 2017.

CLEMENTE, J. P.; FONTANELLI, G.; OVANDO, G. G.; ROA, Y. L. B.; LAPINI, A.; SANTI, E. Google Earth Engine: Application Of Algorithms For Remote Sensing Of Crops In Tuscany (Italy), 2020 IEEE Latin American GRSS & ISPRS Remote Sensing

Conference (LAGIRS), Santiago, Chile, 2020, pp. 195-200, doi: 10.1109/LAGIRS48042.2020.9165561.

CONGALTON, R.G.; GREEN, K. Assessing the Accuracy of Remotely Sensed Data: **Principles and Practices**. Nova York, Boca Raton: Lewis Publishers, 137 p., 1999.

DESTRO, João Norberto; **Modelo para Webmap: Um Estudo de Caso**. Dissertação de Mestrado — Ciências Geodésicas, Universidade Federal do Paraná, Curitiba, 2007.

DORMAN, Michael. Introduction to Web Mapping. 2020

EUROPEAN SPACE AGENCY. **Sentinel-2 User Handbook Document. Technical Report issue 1 revision 2**.: European Space Agency. 2015. Disponível em: https://sentinel.esa.int/documents/247904/685211/Sentinel2\_User\_Handbok. Acesso em: 09/08/2019.

FACELI, K.; LORENA, A.; GAMA, J.; CARVALHO, A. P. L. Inteligência Artificial – Uma Abordagem de Aprendizado de Máquina, LTC, 1a Edição, 2011.

FIGUEIREDO, G. C.; VIEIRA, C. A. O. Estudo do comportamento dos índices de Exatidão Global, Kappa e Tau, comumente usados para avaliar a classificação de imagens do sensoriamento remoto; 2007.

FITZ, P.R. Geoprocessamento sem complicação - São Paulo, SP: Oficina de Textos, 2008.

FLORENZANO, T. G. **Iniciação em Sensoriamento Remoto.** 3. ed. São Paulo: Oficina de Textos, 2011.

FORSTMAIER, A.; SHEKHAR, A.; CHEN, J. Mapping of *Eucalyptus* in Natura 2000 Areas Using Sentinel 2 Imagery and Artificial Neural Networks. *Remote Sens.* 2020, 12, 2176.

FUNK, C.; PETERSON, P.; LANDSFELD, M.; PEDREROS, D.; VERDIN, J.; SHUKLA, S.; HUSAK, G.; ROWLAND, J.; HARRISON, L.; HOELL, A.; MICHAELSEN, J. The climate hazards infrared precipitation with stations—a new environmental record for monitoring extremes. Scientific Data 2, 150066. doi:10.1038/sdata.2015.66, 2015.

GAO, B. C. **NDWI** - A normalized difference water index for remote sensing of vegetation liquid water from space. 1996.

GARCIA-GARCIA, A.; ORTS-ESCOLANO, S.; OPREA, S.; VILLENA-MARTINEZ, V.; GARCIA-RODRIGUEZ, J. A review on deep learning techniques applied to semantic segmentation. arXiv preprint arXiv:1704.06857. 2017

GHASSEMI, S.; SANDU, C.; FIANDROTTI, A.; GIULIO TONOLO, F.; BOCCARDO, P.; FRANCINI, G.; MAGLI, E. **Satellite Image Segmentation with Deep Residual Architectures for Time-Critical Applications**. 2235-2239. 10.23919/EUSIPCO.2018.8553545. 2018.

GOMES, D. M.; Geographical Mapping Of Coffee Crops By Using Convolutional Networks. Belo Horizonte, 2017.

GOODFELLOW, I., BENGIO, Y., COURVILLE, A.: **Deep learning**. MIT Press, Cambridge, 2016.

GOOGLE EARTH ENGINE. **Google Earth Engine**. Disponível em: <a href="https://earthengine.google.com/">https://earthengine.google.com/</a>. Acesso 11 de junho de 2019.

GORELICK, N.; HANCHER, M.; DIXON, M.; ILYUSHCHENKO, S.; THAU, D.; MOORE, R.; Google Earth Engine: Planetary-scale geospatial analysis for everyone. 2017.

GUO, Y.; LIU, Y.; GEORGIOU, T.; LEW, M. A review of semantic segmentation using deep neural networks. International Journal of Multimedia Information Retrieval. 10.1007/s13735-017-0141-z. 2017.

HAKDAOUI, S.; EMRAN, A.; PRADHAN, B.; QNINBA, A.; BALLA, T.E.; MFONDOUM, A.H.N.; LEE, C.-W.; ALAMRI, A.M. Assessing the Changes in the Moisture/Dryness of Water Cavity Surfaces in Imlili Sebkha in Southwestern Morocco by Using Machine Learning Classification in Google Earth Engine. *Remote Sens.* 2020, *12*, 131. https://doi.org/10.3390/rs12010131.

HE, K.; ZHANG, X.; REN, S.; SUN, J. **Deep Residual Learning for Image Recognition**. 770-778. 10.1109/CVPR.2016.90. 2016.

HENRY, C.; AZIMI, S. M.; MERKLE, N. Road Segmentation in SAR Satellite Images With Deep Fully Convolutional Neural Networks. IEEE Geoscience and Remote Sensing Letters 15: 1867-1871. 2018.

HERSBACH, H.; BELL, B.; BERRISFORD, P.; BIAVATI, G.; HORÁNYI, A.; MUÑOZ SABATER, J.; NICOLAS, J.; PEUBEY, C.; RADU, R.; ROZUM, I.; SCHEPERS, D.; SIMMONS, A.; SOCI, C.; DEE, D.; THÉPAUT, J-N. **ERA5 hourly data on single levels from 1979 to present. Copernicus Climate Change Service (C3S) Climate Data Store (CDS)**. (Acessado em: 08/02/2021), 10.24381/cds.adbb2d47, 2018.

HUETE, A. R. A soil-adjusted vegetation index (SAVI). Remote Sensing of Environment, [s.l.], n. 25: 295-309. 1988.

HUETE, A. R.; LIU, H. Q.; BATCHILY, K.; VAN LEEUWEN, W. A Comparison of Vegetation Indices over a Global Set of TM Images for EOS-MODIS. Remote Sens. Environ, n.59, p.440-451, 1997.

IBGE. Instituto Brasileiro de Geografia e Estatísticas. Disponível em: <a href="https://cidades.ibge.gov.br/brasil/ms/panorama">https://cidades.ibge.gov.br/brasil/ms/panorama</a>. Acesso em 24 de janeiro de 2019.

INPE. Manuais: tutorial de geoprocessamento SPRING. 2008.

JENSEN, J. R. **Sensoriamento Remoto do Ambiente**: Uma Perspectiva em recursos terrestres. 2009.

- KHRYASHCHEV, V.; IVANOVSKY, L.; PAVLOV, V.; OSTROVSKAYA, A.; RUBTSOV, **A. Comparison of Different Convolutional Neural Network Architectures for Satellite Image Segmentation**. 23rd Conference of Open Innovations Association (FRUCT), 172-179. 2018.
- KRESTENITIS, M.; ORFANIDIS, G.; IOANNIDIS, K.; AVGERINAKIS, K.; VROCHIDIS, S.; KOMPATSIARIS, I. Oil Spill Identification from Satellite Images Using Deep Neural Networks. *Remote Sens.* 11, 1762. 2019.
- KUMAR, L.; MUTANGA, O. Google Earth Engine Applications Since Inception: Usage, Trends, and Potential. *Remote Sens.* 2018, *10*, 1509. https://doi.org/10.3390/rs10101509
- LECUN, Y.; BENGIO, Y.; HINTON, G. **Deep Learning**. Nature. 521. 436-44. 10.1038/nature14539. 2015.
- LE MAIRE, G.; DUPUY, S.; NOUVELLON, Y.; LOOS, R.A.; HAKAMADA, R. Mapping short-rotation plantations at regional scale using MODIS time series: Case of eucalypt plantations in Brazil. Remote Sens. Environ. 2014, 152, 136–149.
- LIANG, Z.; JINPING, S.; HUIYOND, S.; GANG, Y.; YI, J. Large area Land Cover Classification with LANDSAT ETM+ Images based on Decision Tree. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences, Volume XXXIX-B7. 2012.
- LILLESAND, T.M.; KIEFER, R.W. **Remote Sensing and Image Interpretation**. 3rd ed. New york: John Wiley & Sons, Inc., 750 p., 2015.
- LIU, Y.; WANG, Y.; WANG, S.; LIANG, T.; ZHAO, Q.; TANG, Z.; LING, H. **CBNet: A Novel Composite Backbone Network Architecture for Object Detection**. AAAI, 2020.
- LONG, J.; SHELHAMER, E.; DARRELL, T. Fully Convolutional Networks for Semantic Segmentation, Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2015, pp. 3431-3440
- LUGER, G. L., STUBBLEFIELD, W. A., Artificial Intelligence: Structures and Strategies for Complex Problem Solving, Addison-Wesley, 1997.
- MALAMBO, L.; POPESCU, S.; ROONEY, W.; ZHOU, T.; (2019). A Deep Learning Semantic Segmentation-Based Approach for Field-Level Sorghum Panicle Counting. Remote Sensing. 11. 10.3390/rs11242939.
- MARANHA, L. G.; SANCHES, I. D. A.; MELO, L. F. S. **Análise do comportamento espectro-temporal do Eucalipto na região do município de São Bento do Tocantins**. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 18. (SBSR), 2017, Santos. Anais... São José dos Campos: INPE, 2017. p. 2708-2715. Internet. ISBN 978-85-17-00088-1. IBI: <8JMKD3MGP6W34M/3PSLR5B>. Disponível em: <a href="http://urlib.net/rep/8JMKD3MGP6W34M/3PSLR5B">http://urlib.net/rep/8JMKD3MGP6W34M/3PSLR5B>.</a>

MARQUES, Eduarda Almeida Leão. **Estudo sobre redes neurais de aprendizado profundo com aplicações em classificação de imagens**. 2016. ix, 51 f., il. Monografia, Bacharelado em Estatística —Universidade de Brasília, Brasília, 2016.

MARMANIS, D.; WEGNER, J.; GALLIANI, S.; SCHINDLER, K.; DATCU, M.; STILLA, U. **Semantic Segmentation of aerial images with an ensemble of CNNs**. ISPRS Annals of Photogrammetry, Remote Sensing and Spatial Information Sciences. III-3. 473-480. 10.5194/isprs-annals-III-3-473-2016. 2016.

MARUJO, Rennan De Freitas Bezerra. **Avaliação De Métodos De Segmentação De Imagens Aplicadas Na Classificação De Culturas Cafeeiras**. 2013. Trabalho de Conclusão de Curso, Bacharelado em Ciência da Computação — Universidade Federal de Lavras, Lavras, 2013.

MATTA, J.; CUNHA, M.; SILVA, P.; SANTOS, A. Desenvolvimento de um Webmap, através de softwre livre, para disponibilização da base cartográfica do Campus Viçosa da Universidade Federal de Viçosa. 2017.

MCGLINCHY, J.; JOHNSON, B.; MULLER, B.; JOSEPH, M.; DIAZ, J. Application of UNet Fully Convolutional Neural Network to Impervious Surface Segmentation in Urban Environment from High Resolution Satellite Imagery, IGARSS 2019 - 2019 IEEE International Geoscience and Remote Sensing Symposium, Yokohama, Japan, 2019, pp. 3915-3918, doi: 10.1109/IGARSS.2019.8900453.

MENESES, P.R.; SANO, E.E. Classificação pixel a pixel de imagens. In: MENESES, P.R; ALMEIDA T. DE. (Coordenadores), **Introdução ao processamento de imagens de sensoriamento remoto**. Brasília: UNB, CNPQ, p. 191- 208, 2012.

MITCHELL, T. Machine Learning. New York, McGraw Hill, 1997. 414p.

MOREIRA, M. A. **Fundamentos do Sensoriamento Remoto e Metodologias de Aplicação. 3. ed.** Viçosa, MG: Universidade Federal de Viçosa, 2007. 315 p.

MOTA, F.; GONÇALVES, M.; AGUIAR, M.; ADAMATTI, D. Google Earth Engine e sua aplicabilidade na gestão de recursos hídricos. 161-170. 10.5753/wcama.2020.11030. 2020.

MURUGANANDHAM, S.; Semantic Segmentation of Satellite Images using Deep Learning. Space Engineering, Masters level. Luleå University of Technology Department of Computer Science, Electrical and Space Engineering, 2016.

NOGUEIRA, Keiller. **Going Deep into Remote Sensing Spatial Feature Learning**. 2019. Tese de Doutorado — Universidade Federal de Minas Gerais, Belo Horizonte, 2018.

NOVO, E. M. L. de M. **Sensoriamento Remoto: Princípios e Aplicações**. 2 ed. São Paulo: Edgar Blucher, 1995.

PASHAEI, M.; KAMANGIR, H.; STAREK, M.; TISSOT, P. Review and Evaluation of Deep Learning Architectures for Efficient Land Cover Mapping with UAS Hyper-Spatial Imagery: A Case Study Over a Wetland. Remote Sensing. 12. 959. 10.3390/rs12060959. 2020.

PEVS, Produção da Extração Vegetal e da Silvicultura 2017 — IBGE. Disponível em: <a href="https://agenciadenoticias.ibge.gov.br/media/com\_mediaibge/arquivos/15f538e9095614fc3204f828b22fa714.pdf">https://agenciadenoticias.ibge.gov.br/media/com\_mediaibge/arquivos/15f538e9095614fc3204f828b22fa714.pdf</a>. Acesso em 13 de junho de 2019.

PONZONI, F. J. 2002. Sensoriamento remoto no estudo da vegetação: diagnosticando a mata atlântica. In: RUDORFF, B. F. T.; MORAES, E. C.; PONZONI, F. J.; CAMARGO JÚNIOR, H.; CONFORTE, J. C.; MOREIRA, J. C.; EPIPHANIO, J. C. N.; MOREIRA, M. A.; KAMPEL, M.; ALBUQUERQUE, P. C. G. de; MARTINI, P. R.; FERREIRA, S. H.; TAVARES JÚNIOR, S. S.; SANTOS, V. M. N. dos (Ed.). Curso de uso de sensoriamento remoto no estudo do meio ambiente. São José dos Campos: INPE, 2002. p. 27. Capítulo 8. (INPE-8984-PUD/62)

POTAPOV, P.; LI, X.; HERNANDEZ-SERNA, A.; TYUKAVINA, A.; HANSEN, M.C.; KOMMAREDDY, A.; PICKENS, A.; TURUBANOVA, S.; TANG, H.; SILVA, C.E.; ARMSTON, J.; DUBAYAH, R.; BLAIR, J. B.; HOFTON, M. Mapping and monitoring global forest canopy height through integration of GEDI and Landsat data. 2020. *In review*.

PROVOST, F. J.; FAWCETT, T.; KOHAVI, R. The case against accuracy estimation for comparing induction algorithms. In ICML, vol. 98, pp. 445–453, 1998

REIS, Ricardo Torres Bispo. **Modelos de aprendizado profundo para detecção de planetas extrassolares**. 2018. 58 f. Trabalho de Conclusão de Curso (Bacharelado em Estatística)—Universidade de Brasília, Brasília, 2018.

RICHRDS J. A.; JIA X., Remote Sensing Digital Image Analysis An Introduction, 4th Edition, Springer, p. 193, 2006.

RONNEBERGER, O., FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. MICCAI, 2015.

ROSA, R. Introdução ao sensoriamento remoto. Uberlândia: Ed. UFU, 2007. 248 p.

ROUSE, J. W.; HAAS, R. H.; SCHELL, J. A.; DEERING, D. W. Monitoring vegetation systems in the great plains with ERTS. In: Earth Resources Technology Satellite-1 Symposium, 3., Washington, D. C., 1973. Proceedings. Washington, D. C.: NASA. Goddart Space Flight Center, [s.l.], v. 1, 1973. p. 309-317. (NASA SP-351).

SÃO MIGUEL, A. E.; MEDEIROS, R. B.; OLIVEIRA, W. Análise do uso e cobertura da terra em decorrência da expansão do cultivo de eucalipto no município de Selvíria/MS. Revista eletrônica do curso de geografia — UFG/REG. Jataí. 2016.

SARAIVA, M.; PROTAS, E.; SALGADO, M.; SOUZA, C. Automatic Mapping of Center Pivot Irrigation Systems from Satellite Images Using Deep Learning. Remote Sens. 2020, 12, 558.

SILVA, Daniel Moura da. **Classificação de lavouras por aprendizagem profunda com dados de sensores remotos**. 2018. 108 f., il. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Software)—Universidade de Brasília, Brasília, 2018.

- SILVA, E. A.; MARANGON, G. P.; DESSBESELL, L.; MORAIS, W. W.; LIPPERT, D. B.; PEREIRA, R. S. **Caracterização Espectral na Reflectância de Eucalyptus grandis**. FLORESTA, [S.1.], v. 42, n. 2, p. 285-292, may 2012. ISSN 1982-4688. Disponível em: <a href="https://revistas.ufpr.br/floresta/article/view/17587">https://revistas.ufpr.br/floresta/article/view/17587</a>. Acesso em: 10 sep. 2020. doi:http://dx.doi.org/10.5380/rf.v42i2.17587.
- SILVA, M. L. M..; PEREIRA, G. P. M. Avaliação de algoritmos de classificação supervisionada para imagens do Cbers-2 da Região do Parque Estadual do Rio Doce-MG. Anais XIII Simpósio Brasileiro de Sensoriamento Remoto, Florianópolis, Brasil, 21-26 abril 2007, INPE, p. 6223-6228..
- SOUZA, C.; SHIMBO, J. Z.; ROSA, M.; PARENTE, L.; ALENCAR, A.; RUDORFF, B.; HASENACK, H.; MATSUMOTO, M.; FERREIRA, L.; SOUZA-FILHO, P.; OLIVEIRA, S.; ROCHA, W.; FONSECA, A.; BALZANI, C.; DINIZ, C.; COSTA, D.; MONTEIRO, D.; ROSA, E.; VÉLEZ-MARTIN, E.; AZEVEDO, T.. Reconstructing Three Decades of Land Use and Land Cover Changes in Brazilian Biomes with Landsat Archive and Earth Engine. Remote Sensing. 12. 10.3390/rs12172735. 2020.
- TAMIMINIA, H.; SALEHI, B.; MAHDIANPARI, M.; QUACKENBUSH, L.; ADELI, Brian BRISCO, S. **Google Earth Engine for geo-big data applications: A meta-analysis and systematic review**, ISPRS Journal of Photogrammetry and Remote Sensing, Volume 164, Pages 152-170, ISSN 0924-2716, https://doi.org/10.1016/j.isprsjprs.2020.04.001. 2020.
- TALUKDAR, S.; SINGHA, P.; MAHATO, S.; SHAHFAHAD; PAL, S.; LIOU, Y.; RAHMAN, A. Land-Use Land-Cover Classification by Machine Learning Classifiers for Satellite Observations—A Review. Remote Sensing. 12. 10.3390/rs12071135. 2020.
- TASSI, A.; VIZZARI, M. Object-Oriented LULC Classification in Google Earth Engine Combining SNIC, GLCM, and Machine Learning Algorithms. *Remote Sens.* 2020, *12*, 3776.
- TSO, B.; MATHER, P. Classification methods for remotely sensed data. Danvers: Taylor & Francis Group, 2009.
- VEENENDAAL, B.; BROVELLI, M.A.; LI, S. Review of Web Mapping: Eras, Trends and Directions. *ISPRS Int. J. Geo-Inf.* **2017**, *6*, 317. https://doi.org/10.3390/ijgi6100317
- VENTURIERI, A.; SANTOS, J.R. **Técnicas de classificação de imagens para análise de cobertura vegetal**. In: Assad, E. D.; Sano, E. E. (Ed.). Sistema de Informações Geográficas, Brasília: Embrapa-SPI/Embrapa-CPAC, Capítulo 18, p. 351-371. 1998.
- XIE, Q.; LUONG, M; HOVY, E.; LE, Q. V. **Self-training with Noisy Student improves ImageNet classification**. Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2020, pp. 10687-10698
- YOSHIHARA, A.; HASCOET, T.; TAKIGUCHI, T.; ARIKI, Y. Satellite Image Semantic Segmentation Using Fully Convolutional Network. 2018.

YUAN, Y.; CHEN, X.; WANG, J. Object-Contextual Representations for Semantic Segmentation. 2019.

ZHOU, P.; ZHOU, G.; ZHU, Z.; TANG, C.; HE, Z.; LI, W.; JIANG, F. **Health Monitoring for Balancing Tail Ropes of a Hoisting System Using a Convolutional Neural Network**. Applied Sciences. 8. 1346. 10.3390/app8081346. 2018.

ZHU, X.; TUIA, D.; MOU, L.; XIA, G.; ZHANG, L.; XU, F.; FRAUNDORFER, F. **Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources**. IEEE Geoscience and Remote Sensing Magazine. 5. 8-36. 10.1109/MGRS.2017.2762307. 2017.