



**Universidade de Brasília – UnB**  
**Instituto de Ciências Humanas – IH**  
**Departamento de Geografia – GEA**  
**Programa de Pós-Graduação em Geografia - PÓSGEA**

Universidade de Brasília

Programa de Pós-Graduação em Geografia (PÓSGEA)

**SEGMENTAÇÃO SEMÂNTICA PROFUNDA PARA DETECÇÃO DE FLORESTAS  
PLANTADAS DE EUCALIPTO NO TERRITÓRIO BRASILEIRO USANDO  
IMAGENS SENTINEL-2**

**Luciana Borges da Costa**

Dissertação de Mestrado

Brasília/DF: julho de 2021



**Universidade de Brasília – UnB**  
**Instituto de Ciências Humanas – IH**  
**Departamento de Geografia – GEA**  
**Programa de Pós-Graduação em Geografia - PÓSGEA**

Universidade de Brasília

Programa de Pós-Graduação em Geografia (PÓSGEA)

**SEGMENTAÇÃO SEMÂNTICA PROFUNDA PARA DETECÇÃO DE FLORESTAS  
PLANTADAS DE EUCALIPTO NO TERRITÓRIO BRASILEIRO USANDO  
IMAGENS SENTINEL-2**

**Luciana Borges da Costa**

**Orientador: Osmar Abílio de Carvalho Júnior**

Dissertação de Mestrado

Brasília/DF: julho de 2021

UNIVERSIDADE DE BRASÍLIA  
PÓS-GRADUAÇÃO EM GEOGRAFIA

**SEGMENTAÇÃO SEMÂNTICA PROFUNDA PARA DETECÇÃO DE FLORESTAS  
PLANTADAS DE EUCALIPTO NO TERRITÓRIO BRASILEIRO USANDO  
IMAGENS SENTINEL-2**

Luciana Borges da Costa

Dissertação de Mestrado submetida ao Departamento de Geografia da Universidade de Brasília, como parte dos requisitos necessários para a obtenção do Grau de Mestre em Geografia, área de concentração Gestão Ambiental e Territorial, opção Acadêmica.

Aprovada por:

---

Prof. Dr. Osmar Abílio de Carvalho Júnior, Doutor (UNB)  
(Orientador)

---

Dr. Yosio Edemir Shimabukuro (INPE)  
(Examinador externo)

---

Prof. Dr. Manoel do Couto Fernandes (UFRJ)  
(Examinador externo)

Brasília-DF, 30 de julho de 2021.

## FICHA CATALOGRÁFICA

COSTA, LUCIANA BORGES

Segmentação semântica profunda para detecção de florestas plantadas de eucalipto no território brasileiro usando imagens Sentinel-2, 45 p., (UnB-IH-GEA, Mestre, Gestão Ambiental e Territorial, 2021).

Dissertação de Mestrado – Universidade de Brasília. Departamento de Geografia.

1. Florestas Plantadas

2. Brasil

3. Efficient-net

4. U-net

5. DeepLab

6. Multispectral

## REFERÊNCIA BIBLIOGRÁFICA

COSTA, L. B. **Segmentação semântica profunda para detecção de florestas plantadas de eucalipto no território brasileiro usando imagens Sentinel-2**. 2021, 45 p. Dissertação (Mestrado em Geografia) – Universidade de Brasília, Brasília.

É concedida à Universidade de Brasília Permissão para reproduzir cópia desta dissertação e emprestar ou vender tais cópias somente para propósitos acadêmicos e científicos. A autora reserva outros direitos de publicação e nenhuma parte desta dissertação de mestrado pode ser reproduzida sem a autorização por escrito da autora.

## DEDICATÓRIA

Aos leitores deste trabalho:

“All great and beautiful work has come of first gazing  
without shrinking into the darkness.”

-John Ruskin

## AGRADECIMENTOS

Quando decidi me arriscar pelo mundo acadêmico, questionei sobre minha capacidade em lidar com as dificuldades de ultrapassar a zona de conforto. Porém, nem imaginava que em toda jornada que iniciamos nos encontramos com pessoas incríveis que aliviam um pouco do peso da caminhada.

Agradeço inicialmente aos meus pais, Lilia Maria Borges e Silvio Roberto da Costa por terem sido iluminados com tanta paciência ao me acolherem durante todos esses anos, para que eu pudesse focar apenas em estudar e para que eu pudesse realizar o meu sonho de fazer mestrado. Agradeço, também, aos meus irmãos Lucas Borges da Costa e Ana Flávia Costa por todo apoio em todos os momentos da minha vida.

Agradeço ao professor orientador Dr. Osmar Abílio de Carvalho Junior, por toda sua paciência, cuidado, abertura e disposição ao me receber como orientanda e por ser meu guia nesta jornada acadêmica.

Aos professores Dr. Roberto Arnaldo Trancoso Gomes e Dr. Renato Fontes Guimarães, pelas aulas e pela disponibilidade e tranquilidade em me ajudar com as minhas limitações, curiosidades e aprendizados.

Agradeço aos meus parceiros de trabalho Osmar Luiz Ferreira de Carvalho e Anesmar Olinho de Albuquerque, por me ajudarem a me aprofundar no universo do geoprocessamento e do Deep Learning, com muita paciência, disposição e bom humor.

Agradeço aos meus amigos de curso e de laboratório: à minha amiga Maria Damasceno Bitencourt, por toda ajuda com a escrita da dissertação e pela companhia feita com conversas sem fim; à minha amiga, Krishna Mara Rodrigues Freire, pela companhia nas aulas, pelas conversas profundas e eternas e pelo apoio emocional durante este período do mestrado; e ao Hugo Crisóstomo de Castro Filho, pela disposição em me ajudar com qualquer problema que aparecesse, como equipamentos de laboratório ou dúvidas de conteúdo.

Por fim, mas não menos importante, agradeço ao Universo, que sempre me mostra que em cada desafio encontramos conexões com pessoas tão diferentes, e que apesar das dificuldades e perdas, toda experiência possui maravilhas esperando para serem descobertas.

## RESUMO

As florestas plantadas de eucalipto possuem grande importância econômica para o Brasil e os extratos de eucalipto são utilizados em diversos setores da indústria mundial. As técnicas de sensoriamento remoto são de suprema importância para o estudo e o monitoramento destas áreas, além de ser uma ferramenta essencial para a determinação de planos de ação na economia e na política. O Deep Learning surge atualmente como uma alternativa de automatização e melhoria da eficiência das técnicas de machine learning. Este estudo tem como objetivo analisar o uso da segmentação semântica profunda na detecção de áreas de plantios de eucalipto por meio de imagens Sentinel-2, por ter observado a importância econômica o eucalipto para o desenvolvimento de estudos automatizados para monitoramento desta cultura. O foco deste trabalho é na comparação de seis arquiteturas de Deep Learning (U-net, DeepLabv3 +, FPN, MANet, PSPNet, LinkNet) com quatro codificadores (ResNet-101, ResNeXt-101, Efficient-net-b3 e Efficient-net-b7), usando 10 bandas espectrais, excluindo apenas as 3 bandas relacionadas à atmosfera. Mesmo que as diferenças não fossem grandes entre os diferentes modelos, descobrimos que o Efficient-net-b7 foi o melhor codificador entre todas as arquiteturas e o melhor modelo geral foi DeepLabv3 + com o codificador Efficient-net-b7, alcançando um IoU de 76,57. Além disso, comparamos o mapeamento de grandes imagens de satélite com a técnica de janela deslizante com pixels sobrepostos considerando seis diferentes valores de passada. Descobrimos que as janelas deslizantes com valores de passada mais baixos minimizaram significativamente os erros na borda do quadro, tanto visual quanto quantitativamente (métricas). A segmentação semântica permite uma distinção evidente entre a arborização e a vegetação natural, sendo rápida e eficiente para a análise da distribuição espacial das mudanças da arborização no Brasil. Técnicas mais assertivas na identificação do alvo por meio das imagens de satélite para alimentar as redes de Deep Learning poderão melhorar ainda mais a precisão das informações encontradas por estas redes.

**Palavras-chave:** Florestas Plantadas, Brasil, Efficient-net, U-net, DeepLab, Multispectral.

## SUMÁRIO

<b>CAPÍTULO 1 – APRESENTAÇÃO GERAL</b> .....	11
INTRODUÇÃO .....	11
O EUCALIPTO E SUA INFLUÊNCIA NA ECONOMIA BRASILEIRA .....	11
SENSORIAMENTO REMOTO E DEEP LEARNING PARA FLORESTAS PLANTADAS .....	13
ÁREAS DE ESTUDO.....	16
IMAGENS SENTINEL-2 .....	17
OBJETIVOS .....	18
ESTRUTURAÇÃO DA DISSERTAÇÃO .....	18
REFERÊNCIAS BIBLIOGRÁFICAS .....	19
<b>CAPÍTULO 2 - DEEP SEMANTIC SEGMENTATION FOR DETECTING EUCALYPTUS PLANTED FORESTS IN THE BRAZILIAN TERRITORY USING SENTINEL-2 IMAGERY</b> .....	25
INTRODUCTION .....	25
MATERIAL AND METHODS .....	25
STUDY AREA.....	28
SENTINEL-2 IMAGE, ANNOTATIONS, AND SAMPLE SPLIT.....	29
DEEP LEARNING MODELS .....	30
SCENE MOSAICKING.....	31
EVALUATION METRICS.....	31
RESULTS .....	32
METRICS RESULTS .....	32
MOSAICKING RESULTS .....	33
DISCUSSION.....	35
CONCLUSION.....	38
REFERENCES .....	39
<b>CAPÍTULO 3 - CONCLUSÃO</b> .....	43



## LISTA DE FIGURAS

- Figura 1.1-** Modelo da arquitetura U-net, suas camadas convolucionais escondidas, suas camadas de MaxPooling e de UpSampling. Do lado esquerdo se encontra a etapa de codificação da imagem e do lado direito se encontra a etapa de decodificação da imagem .  
Fonte: Ronneberger et al., 2015 (adaptado).. ..... 15
- Figura 1.2** - Classificação da imagem no modelo de janela deslizante baseada na divisão da imagem em cenas. A janela deslizante (vermelho) se sobrepõe à cena (azul), podendo ocorrer sobreposição dos pixels classificados (amarelo e verde). Fonte: Albuquerque *et al.*, 2020. ... 16
- Figure 2.1-** Location map of the study areas: (A) Teixeira de Freitas region in the South Bahia, (B) Aracruz region in Northern Espírito Santo, and (C) Telêmaco Borba region in the Center-East Paraná. .... 29
- Figure 2.2-** Example of entire scene mosaicking in a 2080x1120-pixel area, with the original image, the ground truth (GT), and the DeepLabv3+ with Efficient-net-b7 (Eff-b7) encoder prediction. .... 36
- Figure 2.3-**Representation of two examples, in which the first (A) shows the appearance of an object by decreasing the stride, and the second (B) the disappearance by decreasing the stride. .... 37

## LISTA DE TABELAS

<b>Table 2.1</b> - Data split and their respective number of samples and percentages. ....	30
<b>Table 2.2</b> - Accuracy Metrics and mathematical expressions.....	32
<b>Table 2.3</b> - Results of accuracy metrics (accuracy (Acc), precision, recall, F-score, IoU, ROC AUC, and PR AUC) for the six architectures (U-net, FPN, DeepLabv3+, MANet, LinkNet, and PSPNet) and four backbones (Eff-b7, Eff-b3, R-101, and X-101).....	33
<b>Table 2.4</b> - Accuracy metrics for mosaicking using 6 different stride values. ....	34

# CAPÍTULO 1 – APRESENTAÇÃO GERAL

## INTRODUÇÃO

### O EUCALIPTO E SUA INFLUÊNCIA NA ECONOMIA BRASILEIRA

O eucalipto pode viver por um milênio e geralmente cresce em áreas com bastante água. Suas flores nascem dentro de um opérculo, característica que resultou em seu nome, de origem grega, que significa “bem coberto”. Perenifólia, pertence à família das *Myrtaceae*, nativa da Austrália e da Ásia e é cultivada por conta da sua biomassa aérea que é fonte para fornecimento de matéria prima para indústrias de celulose e papel, de madeira e indústrias farmacêuticas (Amenu, 2017; Ghasemian *et al.*, 2019; Penín *et al.*, 2020; Sabo e Knezevic, 2019; Zaiton *et al.*, 2020).

A composição de cada planta depende das origens botânicas, localização geográfica e condições climáticas (Bobis *et al.*, 2020). As espécies de eucalipto possuem diferentes propriedades entre si, sendo encontradas propriedades anticarcinogênicas, antimutagênicas, bem como antibacterianas, antioxidante, antiviral, antiprotozoária, antiparasitária e repelente, mostrando serem benéficas para a saúde humana (Bachir e Benali, 2012; Bobis *et al.*, 2020; Chahomchuen, Insuan e Insuan, 2020; Doughty, 2002; Maciel *et al.*, 2010; Medhi *et al.*, 2010; Mohebodini *et al.*, 2021; Pan, Lei e Zhang, 2020; Sabo e Knezevic, 2019; Sargin, 2021). Por conta de suas diversas possibilidades de uso, os extratos do eucalipto se tornaram essenciais, principalmente para o abastecimento do mercado de produtos naturais em substituição aos produtos sintéticos.

Na indústria farmacêutica os extratos do eucalipto são utilizados como biopesticidas no controle dos mosquitos da malária, da leishmaniose e de outros mosquitos e carrapatos transmissores de doenças (Doughty, 2002; Maciel *et al.*, 2010; Medhi *et al.*, 2010; Nguyen, Vu e Hebert, 2018; Pan, Lei e Zhang, 2020; Sargin, 2021). Seus extratos também são utilizados como antibiótico natural por conta de sua atividade microbiana, podendo ser utilizado para tratamento de várias infecções e doenças (Bachir e Benali, 2012). O mel do eucalipto se tornou um produto comercialmente atrativo por conta de suas propriedades naturais e terapêuticas (Bobis *et al.*, 2020). Um estudo conduzido por Mohebodini *et al.* (2021) avaliou, também, os efeitos do óleo essencial de eucalipto em diferentes dietas para performance de crescimento, funções digestivas e na resposta imune de frangos de corte. Além disso, os extratos de eucalipto, atualmente, chamaram atenção para aplicações em nanotecnologias na atuação contra desequilíbrio de microrganismos (Salehi *et al.*, 2019) e no aumento da eficiência em biocombustíveis (Ellappan e Rajendran, 2021).

O eucalipto teve uma importante participação na política e na economia brasileira no século XX. Foi Edmundo Navarro de Andrade que introduziu a pesquisa científica com essa árvore em 1904, com o intuito de abastecer a Companhia Paulista de Estradas de Ferro (Cerqueira Neto, 2012; Doughty, 2002). No Brasil, Andrade encontrou clima favorável e oportunidade econômica. Na década de 70 os investimentos em eucalipto cresceram rapidamente por conta dos incentivos fiscais do II Plano Nacional de Desenvolvimento, incluindo o papel e a celulose nos “principais grupos de insumos básicos” e garantindo abertura no fluxo de exportação. Ainda hoje colhemos o resultado desses empreendimentos, pois o Brasil é um dos maiores produtores da matéria prima do eucalipto, gerando a maior produtividade na silvicultura do eucalipto ao se considerar o volume de madeira produzido por área ao ano (Cerqueira Neto, 2012; Doughty, 2002; FAO, 2016; IBÁ, 2019).

Segundo dados de floresta plantada do Instituto Brasileiro de Geografia e Estatística (IBGE), extraídos do Sistema Nacional de Informações Florestais do Serviço Florestal Brasileiro (SNIF, 2021), a área de floresta plantada de Eucalipto no Brasil, com dados atualizados em dezembro de 2020, é de 7.6 milhões de hectares. De acordo com o relatório IBÁ - Indústria Brasileira de Árvores (2019 e 2020), o setor brasileiro de reflorestamento apresentou crescimento de 12,6% em 2019, atingindo uma receita de R\$ 97,4 bilhões. Esse crescimento registrou uma contribuição no Produto Interno Bruto (PIB) Nacional de 1,2% em 2019, um alto crescimento mesmo após ter sido afetado por crises políticas nacionais causadas pela demora da Reforma da Previdência, e crises políticas internacionais causadas pela guerra comercial entre Estados Unidos e China, gerando dificuldades na recuperação do mercado, afetando, também, as contas externas e a desvalorização da moeda brasileira.

A plantação de eucaliptos se tornou eficaz para reflorestamento por apresentar características físicas e químicas apropriadas, por se adaptar rapidamente em regiões tropicais e subtropicais devido às suas características edafoclimáticas e por sua colheita simplificada (Amenu, 2017; Cerqueira Neto, 2012; FAO, 2016; IBÁ, 2019; Penín *et al.*, 2020; Zaiton *et al.*, 2020).

As florestas plantadas de Eucalipto atuam na redução da pressão sobre florestas naturais e se tornaram relevantes na economia, na sociedade e no meio ambiente (Danson e Curran, 1993; FAO, 2016). Podem ser cultivadas como monocultura de alta rotatividade e produtividade e operam a baixo custo (FAO, 2020; IBÁ, 2019; Penín *et al.*, 2020; Zaiton *et al.*, 2020). O Brasil possui altos investimentos no manejo intensivo do eucalipto, envolvendo pesquisas e melhoramento genético para criação métodos silviculturais mais eficientes (FAO, 2016; IBÁ, 2019). O cultivo altamente produtivo do eucalipto deve ser sustentado de forma

eficaz uma vez que o manejo inadequado pode levar à deterioração da qualidade do solo, pode colocar em risco o abastecimento de água na região e pode provocar desequilíbrio na biodiversidade (Amenu, 2017; FAO, 2016; IBÁ, 2019; Oliveira *et al.*, 2013; Zaiton *et al.*, 2020).

As plantações de eucalipto modificaram a paisagem rural, transformaram e influenciaram a dinâmica urbana e seu mercado cresce todos os anos pela crescente importância da produção mundial de celulose (Cerqueira Neto, 2012; Chahomchuen, Insuan e Insuan, 2020; Doughty, 2002). É necessária maior produção de madeira para atender à demanda cada vez maior por seus produtos. Este aumento de produção deve vir de melhorias na produtividade ou de uma maior expansão das florestas plantadas, portanto, as melhorias nas tecnologias de Sensoriamento Remoto contribuirão com a descoberta de novas áreas para plantio e na melhoria das técnicas de manejo intensivo (Dye, 2000; Zaiton *et al.*, 2020).

#### **SENSORIAMENTO REMOTO E DEEP LEARNING PARA FLORESTAS PLANTADAS**

O Sensoriamento Remoto de imagens é uma das técnicas utilizadas para análises e monitoramento ambiental e geográfico e é aplicado para diversas áreas, principalmente para classificação e detecção de mudanças. (Li *et al.*, 2018; Zhu, Tuia, Mou, Xia, G. S., *et al.*, 2017). No Brasil, o monitoramento de plantios de eucalipto é de suprema importância por conta do alto investimento na produção de madeira e diversos métodos têm sido propostos para desenvolver uma classificação de forma automatizada (Dias *et al.*, 2020; Xu *et al.*, 2018). O Deep Learning para Sensoriamento Remoto é uma técnica que surgiu para resolver questões das técnicas de Machine Learning, como dificuldades de precisão na classificação de florestas por conta da complexidade estrutural apresentada nas imagens, permitindo gerar maior eficiência na classificação de dados (Ma *et al.*, 2019; Xu *et al.*, 2018).

O Deep Learning (redes neurais artificiais) como alternativa para análises de dados em sensoriamento remoto aumentou bastante nos últimos anos devido sua habilidade em utilizar os próprios dados de entrada como informações de aprendizado. A própria rede neural possui a capacidade de calcular padrões simples ou mais complexos, sem a necessidade de informações adicionais às informações da própria imagem. A rede neural é treinada por meio de uma máscara da verdade e, após este treinamento, realiza a classificação nas imagens que serão entregues a ela. Ou seja, a rede neural artificial entrega uma imagem classificada apenas por meio das informações da imagem de entrada sem a necessidade de entregar qualquer outra informação além desta. Para isso, as redes neurais artificiais possuem mais de duas camadas de aprendizado e necessitam de grandes quantidades de dados de entrada para evitar o

overfitting (Dias *et al.*, 2020; Li *et al.*, 2018; Schmidhuber, 2015; Xie *et al.*, 2017; Zhu *et al.*, 2017).

Uma das arquiteturas de Deep Learning que mais se destacaram nos últimos anos para utilização em Sensoriamento Remoto são as chamadas Redes Neurais Convolucionais (CNN). A CNN é uma arquitetura de multicamadas contendo vários estágios de extração de recursos subdivididos em três camadas: (a) uma camada convolucional, (b) uma camada não linear e (c) uma camada de pooling (Zhang *et al.*, 2016). As camadas convolucionais filtram os padrões das imagens, reconhecendo os padrões dos dados de entrada da imagem bruta, efetuando a saída desta imagem transformada na próxima camada de convolução. A camada não linear consiste em uma função de ativação, uma vez que as imagens passam pela seguinte sequência: (1) camada convolucional de entrada; (2) camadas convolucionais ocultas; e, por fim, (3) camadas de saída, de forma que os valores passam por análises de peso com bases em erros para que as dimensões da entrada e da saída sejam idênticas. As camadas de pooling são as responsáveis pela diminuição da dimensão da imagem, de forma a diminuir o custo computacional da operação. Essas camadas de diminuição da dimensão das imagens servem para que seja possível examinar áreas maiores em cada aprendizado, ao mesmo tempo em que reduz a quantidade de parâmetros na rede, algo comparado ao ato de afastarmos uma imagem de nossos olhos para entendermos melhor em qual contexto esta imagem se encontra (Li *et al.*, 2018; Wagner *et al.*, 2019; Zhu *et al.*, 2017).

As CNNs são capazes de perceber padrões por meio de imagens brutas sem nenhum conhecimento anterior à sua tarefa de aprendizado. No caso deste estudo, que faz a segmentação semântica de imagens, ou seja, a classificação de uma informação específica, é necessário apenas entregar as máscaras da verdade com seus rótulos pré-definidos informando qual feição a rede deverá aprender para que ela possa, então, classificar automaticamente. (Wagner, 2019; Ying Li, 2018; Zhu, 2017).

A **Figura 1.1** mostra a arquitetura da rede neural artificial U-net, conforme modelo de Ronneberger *et al.* (2015). Todas as outras arquiteturas de CNNs seguem esta mesma base no desenho de suas próprias arquiteturas, em que do lado esquerdo está a etapa de codificação da imagem e do lado direito está a etapa da decodificação da imagem. Na primeira etapa, ou etapa de codificação da imagem, a rede realizará diversas convoluções na imagem de entrada (reconhecimento de padrões na imagem ou filtragem da imagem) e realizará o MaxPooling (diminuição da dimensão da imagem). Na segunda etapa, ou etapa de decodificação da imagem, a rede realizará UpSampling (retorno da dimensão original da imagem) e irá realizar a classificação da imagem, ou reconhecimento dos alvos de estudo. As diferenças entre os

diversos tipos de arquiteturas de redes CNNs estão nas quantidades e nos tipos de convoluções que a imagem irá sofrer, o que dependerá dos alvos que se espera classificar.

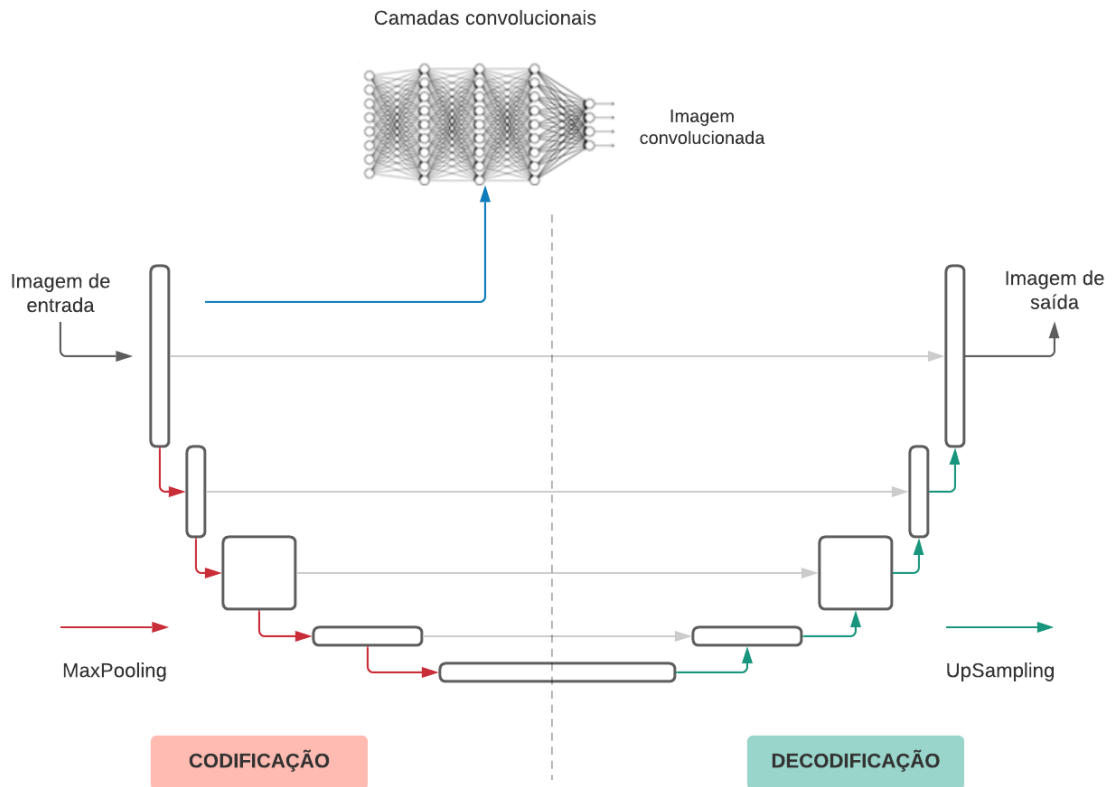


Figura 1.1- Modelo da arquitetura U-net, suas camadas convolucionais escondidas, suas camadas de MaxPooling e de UpSampling. Do lado esquerdo se encontra a etapa de codificação da imagem e do lado direito se encontra a etapa de decodificação da imagem . Fonte: Ronneberger *et al.*, 2015 (adaptado).

O uso do Sensoriamento Remoto para estudos florestais pode ocorrer em 3 níveis: 1- pixel; 2- objeto; 3- povoamento (Dechesne *et al.*, 2017). Segmentação semântica profunda de imagens pertence ao campo de visão computacional e atribui rótulos para cada pixel, ou seja, é uma classificação em nível de pixel. A Segmentação Semântica foi escolhida por ser uma das técnicas de Deep Learning que classificaria nos limites exatos do alvo. O algoritmo de segmentação semântica identifica e classifica quais pixels pertencem juntos semanticamente (Guo *et al.*, 2018). Ao observar aglomerados de florestas plantadas de eucalipto entre outras florestas, este algoritmo analisa quais pixels pertencem semanticamente aos grupos de eucalipto e quais não fariam parte deste alvo, como, por exemplo, matas ciliares ou outras culturas de plantio.

A segmentação semântica resolve problemas de classificação em Sensoriamento Remoto de forma automática, gerando uma delimitação refinada de objetos por ter um entendimento de alto nível de todo o cenário que o envolve (Dias *et al.*, 2019; Xu *et al.*, 2018;

Yuan, Shi e Gu, 2021). Classificação por Sensoriamento Remoto de imagens em nível de pixel possui um papel importante em diversas aplicações, como reconhecimento de plantios (Dechesne *et al.*, 2017; Wagner *et al.*, 2019), monitoramento de mudanças na cobertura do solo, além de avaliação de impactos ambientais, mapeamento de tipos de florestas, estimativa de biomassa, detecção de espécies invasoras e descoberta de novas áreas (Audebert, Saux, Le e Lefèvre, 2018; Xu *et al.*, 2018; Dechesne *et al.*, 2017; Wagner *et al.*, 2019).

Por fim, a classificação das imagens é feita conforme modelo de janela deslizante desenvolvido por Albuquerque *et al.* (2020). Essa janela deslizante tem a mesma dimensão da imagem de entrada e desliza sobre a cena, classificando-a. Essa técnica se mostrou mais eficiente quando a janela deslizante possui menores valores de passada, ou seja, menor dimensão do que a imagem de entrada, sobrepondo-se a cada movimentação, conforme demonstrado na **Figura 1.2**. Essa sobreposição da janela deslizante sobre os pixels da cena a ser classificada diminui a quantidade de erros de borda ao suavizar os valores dos pixels sobrepostos, gerando maior precisão nos resultados da classificação.




Figura 1.2 - Classificação da imagem no modelo de janela deslizante baseada na divisão da imagem em cenas. A janela deslizante (vermelho) se sobrepõe à cena (azul), podendo ocorrer sobreposição dos pixels classificados (amarelo e verde). Fonte: Albuquerque *et al.*, 2020.

## ÁREAS DE ESTUDO

As áreas escolhidas para o estudo do melhor conjunto arquitetura/codificador para classificação de florestas plantadas foram: (1) Teixeira de Freitas, localizada no extremo sul da Bahia; (2) Aracruz, no norte do Espírito Santo; e (3) Telêmaco Borba, no centro-leste do Paraná. Essas áreas foram escolhidas por serem áreas importantes no plantio de eucalipto no Brasil, possuindo grandes áreas de florestas plantadas desta árvore concentradas em uma única região, possibilitando uma maior quantidade de dados para o treinamento das Redes Neurais Artificiais.



Segundo dados de floresta plantada do IBGE, extraídos do Sistema Nacional de Informações Florestais do Serviço Florestal Brasileiro (SNIF, 2021), com dados atualizados de dezembro de 2020, o estado da Bahia possui uma área plantada de eucalipto de 599.562 ha, correspondendo a 7,87% da área plantada de eucalipto nacional; o Espírito Santo possui uma área plantada de eucalipto de 274.093 ha, correspondendo a 3,60% da área plantada de eucalipto nacional; e o estado do Paraná com 666.308 ha de área plantada de eucalipto, correspondendo a 8,75% da área plantada de eucalipto nacional.

O município de Telêmaco Borba, no Paraná, é uma região pioneira no cultivo do eucalipto no Brasil. O município de Aracruz, no Espírito Santo, surgiu, basicamente, com o crescimento das plantações de eucalipto na região e levou o eucalipto para o município de Teixeira de Freitas, no sul da Bahia, por conta de sua proximidade. Todas essas regiões abrigam algumas das maiores empresas brasileiras de papel e celulose e de outros produtos do eucalipto, como madeira e carvão vegetal. Essas áreas localizam-se em regiões estratégicas para o transporte dos extratos de eucalipto para exportação e possuem características edafoclimáticas para o cultivo do eucalipto (Cerqueira Neto, 2012; Netto e Silva, 2008).

A região do extremo sul da Bahia possui relevo que varia de planaltos e serras a planícies e tabuleiros litorâneos. O clima predominante é o tropical úmido com temperaturas entre 20° e 25°C (Neto e Gonçalves, 2009).

A região do norte do Espírito Santo possui relevo de planície e tabuleiros litorâneos e clima tropical úmido, com temperatura média de 23°C (Martins *et al.*, 2003).

A região do centro leste do Paraná possui relevo plano a levemente ondulado e clima subtropical úmido, com temperaturas que variam de 13,5° a 22,4°C (Ferronato *et al.*, 2013).

## IMAGENS SENTINEL-2

O programa escolhido para obtenção das imagens série-temporais e multisensores da área de estudo foi Copernicus, pertencente à Agência Espacial Europeia. Este programa de observação da Terra pertence à União Europeia e entrega dados em tempo real, a nível global e com acesso aberto. Este programa garantirá a aquisição de dados contínuos por décadas. Com a família de satélites Sentinel, composta por seis satélites para monitoramento de diferentes aspectos da superfície terrestre, coleta imagens ópticas, radar, altimétricas, de monitoramento da composição atmosférica. Neste trabalho, serão usadas as imagens Sentinel-2, que são imagens ópticas/multiespectrais, nos procedimentos que precedem a classificação de áreas de eucaliptos plantadas. A missão Sentinel-2 é composta por uma constelação de dois satélites gêmeos, Sentinel-2A e Sentinel-2B, fornece imagens ópticas na faixa do visível, no

infravermelho próximo e infravermelho de onda curta, com uma resolução espacial de 10, 20 e 60 metros, com tempo de revisita de 10 dias no equador com 1 satélite, 5 dias com 2 satélites em condições sem nuvens, resultando entre 2 e 3 dias em latitudes médias (European Union's Earth Observation Program, 2021; Ienco *et al.*, 2019).

## **OBJETIVOS**

Este estudo tem como objetivo avaliar diferentes técnicas de segmentação semântica profunda para detecção de florestas plantadas de eucalipto utilizando imagens Sentinel-2. Esta pesquisa faz a comparação de seis arquiteturas de Deep Learning: (1) U-net; (2) DeepLabv3+; (3) PSPNet; (4) Linknet; (5) MANet; e (6) FPN, com quatro diferentes codificadores: (1) ResNet-101; (2) ResNeXt-101; (3) Efficient-net-b3; e (4) Efficient-net-b7, usando as imagens nas 10 bandas espectrais, excluindo apenas as 3 bandas relacionadas à atmosfera. Para o mapeamento de imagens grandes, utilizamos uma técnica chamada janela deslizante e, para isso, comparamos seis valores de passada: 160, 80, 40, 20, 10 e 5 pixels. Esse procedimento foi aplicado em uma imagem com a dimensão de 2080x1120 pixels.

Todas essas seis arquiteturas de CNNs utilizadas para a análise das suas aplicabilidades na classificação em imagens de sensoriamento remoto, em conjunto com os quatro diferentes codificadores (que também são arquiteturas CNNs), são arquiteturas de Deep Learning desenhadas para análise de imagens. Atualmente, temos a DeepLabv3+ como o estado da arte em inteligência artificial para análises de imagens e temos a U-net como a pioneira entre as arquiteturas de Deep Learning para os estudos de imagens.

## **ESTRUTURAÇÃO DA DISSERTAÇÃO**

Esta dissertação está organizada no formato de artigo científico, obedecendo aos critérios estabelecidos pelo programa de pós-graduação em Geografia da Universidade de Brasília. Neste Capítulo 1 tivemos a contextualização do conteúdo, com a descrição do problema, a motivação e o objetivo geral do trabalho. O Capítulo 2 contém o corpo do artigo científico no formato de submissão à revista *Geocarto International*, da editora Taylor & Francis Group, com o título “Deep Semantic Segmentation for Detecting Eucalyptus Planted Forests in the Brazilian Territory Using Sentinel-2 Imagery”. O Capítulo 3 contém a conclusão desta dissertação para o encerramento deste estudo.

Este é um manuscrito aceito de um artigo publicado por Taylor & Francis no Journal of Geocarto International em 28 de junho de 2021, disponível em: <https://www.tandfonline.com/doi/abs/10.1080/10106049.2021.1943009>.

## REFERÊNCIAS BIBLIOGRÁFICAS

ALBUQUERQUE, A. O. DE *et al.* Deep semantic segmentation of center pivot irrigation systems from remotely sensed data. **Remote Sensing**, v. 12, n. 13, 2020.

AMENU, B. T. Review on Impact of Eucalyptus Plantation on the Soil. **International Journal of Scientific Research in Civil Engineering** © 2017 IJSRCE, v. 2, n. 2, p. 37–43, 2017.

ASSOCIAÇÃO BRASILEIRA DE ÁRVORES. **Brazilian Tree Industry Annual Report 2019. Associação Brasileira de Árvores**. Brasília, Federal District, Brazil: [s.n.].

ASSOCIAÇÃO BRASILEIROA DE ÁRVORES. **Brazilian Tree Industry Annual Report 2020. Associação Brasileira de Árvores**. Brasília, Federal District, Brazil: [s.n.].

AUDEBERT, N.; SAUX, B. LE; LEFÈVRE, S. Beyond RGB: Very high resolution urban remote sensing with multimodal deep networks. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 140, p. 20–32, 2018.

BACHIR, R. G.; BENALI, M. Antibacterial activity of the essential oils from the leaves of Eucalyptus globulus against Escherichia coli and Staphylococcus aureus. **Asian Pacific Journal of Tropical Biomedicine**, v. 2, n. 9, p. 739–742, 2012.

BARANOWSKI, K. *et al.* Application of Reflectance Ratios on High-Resolution Satellite Imagery to Remotely Identify Eucalypt Vegetation. **Remote Sensing**, v. 12, n. 24, p. 4079, dez. 2020.

BEM, P. P. DE *et al.* Performance analysis of deep convolutional autoencoders with different patch sizes for change detection from burnt areas. **Remote Sensing**, v. 12, n. 16, p. 1–19, 2020.

BINKLEY, D. *et al.* Variation in whole-rotation yield among Eucalyptus genotypes in response to water and heat stresses: The TECHS project. **Forest Ecology and Management**, v. 462, n. December 2019, p. 117953, 2020.

BOBIS, O. *et al.* Eucalyptus honey: Quality parameters, chemical composition and health-promoting properties. **Food Chemistry**, v. 325, n. April, p. 126870, 2020.

BRODRICK, P. G.; DAVIES, A. B.; ASNER, G. P. Uncovering Ecological Patterns with Convolutional Neural Networks. **Trends in Ecology & Evolution**, v. 34, n. 8, p. 734–745, ago. 2019.

CARVALHO, O. L. F. DE *et al.* Instance Segmentation for Large, Multi-Channel Remote Sensing Imagery Using Mask-RCNN and a Mosaicking Approach. **Remote Sensing**, v. 13, n. 1, p. 39, dez. 2021.

CERQUEIRA NETO. TRÊS DÉCADAS DE EUCALIPTO NO EXTREMO SUL DA BAHIA. **GEOUSP - Espaço e Tempo, São Paulo**, n. N°31, p. 55–68, 2012.

CHAHOMCHUEN, T.; INSUAN, O.; INSUAN, W. Chemical profile of leaf essential oils from four Eucalyptus species from Thailand and their biological activities. **Microchemical Journal**, v. 158, n. July, p. 105248, 2020.

CHAURASIA, A.; CULURCIELLO, E. LinkNet: Exploiting encoder representations for efficient semantic segmentation. **2017 IEEE Visual Communications and Image Processing, VCIP 2017**, v. 2018- Janua, p. 1–4, 2017.

CHEN, L. C. *et al.* DeepLab: Semantic Image Segmentation with Deep Convolutional Nets, Atrous Convolution, and Fully Connected CRFs. **IEEE Transactions on Pattern Analysis and Machine Intelligence**, v. 40, n. 4, p. 834–848, 2018.

DANSON, F. M.; CURRAN, P. J. Factors affecting the remotely sensed response of coniferous forest plantations. **Remote Sensing of Environment**, v. 43, n. 1, p. 55–65, 1993.

DECHESNE, C. *et al.* SEMANTIC SEGMENTATION of FOREST STANDS of PURE SPECIES AS A GLOBAL OPTIMIZATION PROBLEM. **ISPRS Annals of the Photogrammetry, Remote Sensing and Spatial Information Sciences**, v. 4, n. 1W1, p. 141–148, 2017.

DIAS, D. *et al.* Pixelwise Remote Sensing Image Classification Based on Recurrence Plot Deep Features. **International Geoscience and Remote Sensing Symposium (IGARSS)**, p. 1310–1313, 2019.

DIAS, D. *et al.* Image-Based Time Series Representations for Pixelwise Eucalyptus Region Classification: A Comparative Study. **IEEE Geoscience and Remote Sensing Letters**, v. 17, n. 8, p. 1450–1454, 2020.

DOUGHTY, R. W. The Eucalyptus: a Natural and Commercial History of the Gum Tree. **Journal of Historical Geography**, v. 28, n. 2, p. 290–291, 2002.

DRUSCH, M. *et al.* Sentinel-2: ESA’s Optical High-Resolution Mission for GMES Operational Services. **Remote Sensing of Environment**, v. 120, p. 25–36, maio 2012.

DYE, P. J. Water use efficiency in South African Eucalyptus plantations: A review. **Southern African Forestry Journal**, v. 5925, n. 189, p. 17–26, 2000.

ELLAPPAN, S.; RAJENDRAN, S. A comparative review of performance and emission characteristics of diesel engine using eucalyptus-biodiesel blend. **Fuel**, v. 284, n. June 2020, p. 118925, 2021.

EUROPEAN UNION’S EARTH OBSERVATION PROGRAM. **Copernicus**. Disponível em: <<https://www.copernicus.eu/en>>. Acesso em: 2 março de 2021.

FAN, T. *et al.* Ma-net: A multi-scale attention network for liver and tumor segmentation. **IEEE Access**, v. 8, p. 179656–179665, 2020.

FAO. **Global Forest Resources Assessment 2015** Food and Agriculture Organization of the United Nations. [s.l: s.n.].

FAO. **Global Forest Resources Assessment 2020 - Main Report** Food and Agriculture Organization of the United Nations. [s.l: s.n.].

FERRONATO, M. Z. *et al.* Distribuição espacial e densidade de formigueiros dos gêneros

Atta e Acromyrmex em áreas de pré-plantio de Eucalyptus, no município de Telêmaco Borba, PR. **Encic. Biosfera**, v. 9(16), p. 768–778, 2013.

FORSTMAIER, A.; SHEKHAR, A.; CHEN, J. Mapping of Eucalyptus in Natura 2000 areas using Sentinel 2 imagery and artificial neural networks. **Remote Sensing**, v. 12, n. 14, p. 4–6, 2020.

GHASEMIAN, A. *et al.* Eucalyptus camaldulensis properties for use in the eradication of infections. **Comparative Immunology, Microbiology and Infectious Diseases**, v. 65, n. April, p. 234–237, 2019.

GOODWIN, N.; TURNER, R.; MERTON, R. Classifying Eucalyptus forests with high spatial and spectral resolution imagery: an investigation of individual species and vegetation communities. **Australian Journal of Botany**, v. 53, n. 4, p. 337, 2005.

GUO, Y. *et al.* A review of semantic segmentation using deep neural networks. **International Journal of Multimedia Information Retrieval**, v. 7, n. 2, p. 87–93, 2018.

HE, K. *et al.* **Deep Residual Learning for Image Recognition** 2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). **Anais...** Las Vegas, NV, USA: IEEE, jun. 2016

HOESER, T.; KUENZER, C. Object Detection and Image Segmentation with Deep Learning on Earth Observation Data: A Review-Part I: Evolution and Recent Trends. **Remote Sensing**, v. 12, n. 10, p. 1667, maio 2020.

IBÁ. **Indústria Brasileira de Árvores - Relatório 2019**. [s.l: s.n.]. Disponível em: <<https://www.iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>>. Acesso em 4 de abril de 2020

IBÁ. **Indústria Brasileira de Árvores - Relatório 2020. Associação Brasileira de Árvores**. [s.l: s.n.]. Disponível em: <<http://abpa-br.org/relatorios/>>. Acesso em 4 de abril de 2020.

IBGE. **Clima | 2002 Clima – 1:5 000 000 | IBGE**. Disponível em: <<https://www.ibge.gov.br/geociencias/informacoes-ambientais/15817-clima.html?=&t=downloads>>. Acesso em: 23 março de 2021a.

IBGE. **Unidades de Relevo 1:5.000.000 | 2006 | IBGE**. Disponível em: <<https://www.ibge.gov.br/geociencias/informacoes-ambientais/geomorfologia/15827-unidades-de-relevo.html?=&t=downloads>>. Acesso em: 23 março de 2021b.

IENCO, D. *et al.* Combining Sentinel-1 and Sentinel-2 Satellite Image Time Series for land cover mapping via a multi-source deep learning architecture. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 158, n. p. 11–22, 2019.

KATTENBORN, T. *et al.* Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 173, n. December 2020, p. 24–49, 2021.

LECUN, Y. *et al.* Gradient-based learning applied to document recognition. **Proceedings of the IEEE**, v. 86, n. 11, p. 2278–2324, 1998.

LI, Y. *et al.* Deep learning for remote sensing image classification: A survey. **Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery**, v. 8, n. 6, p. 1–17,

2018.

LIN, T. Y. *et al.* Feature pyramid networks for object detection. **Proceedings - 30th IEEE Conference on Computer Vision and Pattern Recognition, CVPR 2017**, v. 2017- Janua, p. 936–944, 2017.

LIU, L. *et al.* Deep Learning for Generic Object Detection: A Survey. **International Journal of Computer Vision**, v. 128, n. 2, p. 261–318, 2020.

LONG, J.; SHELHAMER, E.; DARRELL, T. Fully Convolutional Networks for Semantic Segmentation. **Intas Polivet**, v. 10, n. 2, p. 227–228, 2015.

MA, L. *et al.* Deep learning in remote sensing applications: A meta-analysis and review. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 152, n. April, p. 166–177, 2019.

MACIEL, M. V *et al.* Veterinary Parasitology Chemical composition of Eucalyptus spp . essential oils and their insecticidal effects on Lutzomyia longipalpis. **Veterinary Parasitology**, v. 167, p. 1–7, 2010.

MARTINS, S. G. *et al.* Perdas de solo e água por erosão hídrica em sistemas florestais na região de Aracruz (ES). **Revista Brasileira de Ciência do Solo**, v. 27, n. 3, p. 395–403, 2003.

MCMAHON, D. E.; JACKSON, R. B. Management intensification maintains wood production over multiple harvests in tropical Eucalyptus plantations. **Ecological Applications**, v. 29, n. 4, p. 1879, jun. 2019.

MEDHI, S. M. *et al.* Phytochemistry and larvicidal activity of E ucalyptus camaldulensis against malaria vector , A nopheles stephensi. **Asian Pacific Journal of Tropical Biomedicine**, p. 841–845, 2010.

MOHEBODINI, H. *et al.* Productive parameters, cecal microflora, nutrient digestibility, antioxidant status, and thigh muscle fatty acid profile in broiler chickens fed with Eucalyptus globulus essential oil. **Poultry Science**, p. 100922, 2021.

MOKOCHINSKI, J. B. *et al.* Metabolic responses of Eucalyptus species to different temperature regimes. **Journal of Integrative Plant Biology**, v. 60, n. 5, p. 397–411, maio 2018.

NETO, C.; GONÇALVES, S. P. Do isolamento regional à globalização: Contradições sobre o desenvolvimento do extremo sul da Bahia. **Tese De Doutorado**, p. 339, 2009.

NETTO, S. P. G. DE C.; SILVA, S. B. DE M. E. Eucaliptização: um processo de especialização do Extremo Sul da Bahia? **Campo Território**, v. 3, n. 6, p. 85–108, 2008.

NGUYEN, Q.-B. D.; VU, M.-A. N.; HEBERT, A. A. Insect Repellents: An Updated Review for the Clinician. **Journal of the American Academy of Dermatology**, 2018.

NOGUEIRA, K.; PENATTI, O. A. B.; SANTOS, J. A. DOS. Towards better exploiting convolutional neural networks for remote sensing scene classification. **Pattern Recognition**, v. 61, p. 539–556, 2017.

OLIVEIRA, A. H. *et al.* WATER EROSION IN SOILS UNDER EUCALYPTUS FOREST AS AFFECTED BY DEVELOPMENT STAGES AND MANAGEMENT SYSTEMS.

**Ciencia e Agrotecnologia**, v. 37, n. 2, p. 159–169, 2013.

PAN, M.; LEI, Q.; ZHANG, H. Industrial Crops & Products Prediction and confirmation of active ingredients in Eucalyptus globulus Labill leaves. **Industrial Crops & Products**, v. 154, n. January, p. 112631, 2020.

PAYN, T. *et al.* Changes in planted forests and future global implications. **Forest Ecology and Management**, v. 352, p. 57–67, 2015.

PENÍN, L. *et al.* Technologies for Eucalyptus wood processing in the scope of biorefineries: A comprehensive review. **Bioresource Technology**, v. 311, n. April, p. 123528, 2020.

RONNEBERGER, O.; FISCHER, P.; BROX, T. U-Net: Convolutional Networks for Biomedical Image Segmentation. *In*: NAVAB, N. *et al.* (Eds.). **Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)**. Cham: Springer, 2015. v. 9351p. 234–241.

SABO, A. V.; KNEZEVIC, P. Antimicrobial activity of Eucalyptus camaldulensis Dehn. plant extracts and essential oils: A review. **Industrial Crops and Products**, v. 132, n. March, p. 413–429, 2019.

SALEHI, B. *et al.* Trends in Food Science & Technology Insights into Eucalyptus genus chemical constituents , biological activities and health-promoting effects. v. 91, n. April, p. 609–624, 2019.

SARGIN, S. A. Potential anti-influenza effective plants used in Turkish folk medicine: A review. **Journal of Ethnopharmacology**, v. 265, n. May 2020, p. 113319, 2021.

SCHMIDHUBER, J. Deep Learning in neural networks: An overview. **Neural Networks**, v. 61, p. 85–117, 2015.

SHANG, X.; CHISHOLM, L. A. Classification of Australian Native Forest Species Using Hyperspectral Remote Sensing and Machine-Learning Classification Algorithms. **IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing**, v. 7, n. 6, p. 2481–2489, jun. 2014.

SIBANDA, M. *et al.* Mapping the Eucalyptus spp woodlots in communal areas of Southern Africa using Sentinel-2 Multi-Spectral Imager data for hydrological applications. **Physics and Chemistry of the Earth**, n. February, p. 102999, 2021.

SIMONYAN, K.; ZISSERMAN, A. Very Deep Convolutional Networks for Large-Scale Image Recognition. set. 2014.

SISTEMA NACIONAL DE INFORMAÇÕES FLORESTAIS - SNIF. **Florestas Plantadas**. Disponível em: <<https://snif.florestal.gov.br/pt-br/florestas-plantadas>>. Acesso em: 2 mar. 2021.

SZEGEDY, C. *et al.* Going Deeper with Convolutions. **IEEE Conference on Computer Vision and Pattern Recognition (CVPR)**., v. 91, p. 319–338, 2015.

TAN, M.; LE, Q. V. EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. **arXiv**, maio 2019.

TRISASONGKO, B. H.; PAULL, D. A review of remote sensing applications in tropical

forestry with a particular emphasis in the plantation sector. **Geocarto International**, v. 35, n. 3, p. 317–339, 2020.

WAGNER, F. H. *et al.* Using the U-net convolutional network to map forest types and disturbance in the Atlantic rainforest with very high resolution images. **Remote Sensing in Ecology and Conservation**, v. 5, n. 4, p. 360–375, 2019.

XIE, S. *et al.* **Aggregated Residual Transformations for Deep Neural Networks** 2017 IEEE Conference on Computer Vision and Pattern Recognition (CVPR). **Anais...Honolulu, HI, USA: IEEE**, jul. 2017

XU, Y. *et al.* Hyperspectral image classification via a random patches network. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 142, n. February, p. 344–357, 2018.

YI, Y. *et al.* Semantic Segmentation of Urban Buildings from VHR Remote Sensing Imagery Using a Deep Convolutional Neural Network. **Remote Sensing**, v. 11, n. 15, p. 1774, jul. 2019.

YUAN, X.; SHI, J.; GU, L. A review of deep learning methods for semantic segmentation of remote sensing imagery. **Expert Systems with Applications**, v. 169, n. December 2020, p. 114417, 2021.

ZAITON, S. *et al.* Eucalyptus in Malaysia: Review on environmental impacts. **Journal of Landscape Ecology(Czech Republic)**, v. 13, n. 2, p. 79–94, 2020.

ZHANG, LIANGPEI; ZHANG, LEFEI; DU, B. Deep learning for remote sensing data: A technical tutorial on the state of the art. **IEEE Geoscience and Remote Sensing Magazine**, v. 4, n. 2, p. 22–40, 2016a.

ZHANG, Y. *et al.* Fully Convolution Adaption. **Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition**, p. 6810–6818, 2018.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G. S.; *et al.* Deep learning in remote sensing: a review. **arXiv**, n. december, 2017.

ZHU, X. X.; TUIA, D.; MOU, L.; XIA, G.; *et al.* Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. **IEEE Geoscience and Remote Sensing Magazine**, v. 5, n. 4, p. 8–36, dez. 2017.



## **CAPÍTULO 2 - DEEP SEMANTIC SEGMENTATION FOR DETECTING EUCALYPTUS PLANTED FORESTS IN THE BRAZILIAN TERRITORY USING SENTINEL-2 IMAGERY**

**ABSTRACT:** This research aims to analyze the use of deep semantic segmentation to detect eucalyptus afforestation areas using Sentinel-2 images. The study compared six architectures (U-net, DeepLabv3+, FPN, MANet, PSPNet, LinkNet) with four encoders (ResNet-101, ResNeXt-101, Efficient-net-b3, and Efficient-net-b7), using 10 spectral bands. Even though the differences were not large among the different models, we found that the Efficient-net-b7 was the best backbone among all architectures, and the best overall model was DeepLabv3+ with the Efficient-net-b7 backbone, achieving an IoU of 76.57. Moreover, we compared the mapping of large satellite images with the sliding window technique with overlapping pixels considering six stride values. We found that sliding windows with lower stride values significantly minimized errors in the frame edge both visually and quantitatively (metrics). Semantic segmentation allows an evident distinction between the afforestation and the natural vegetation, being fast and efficient for spatial distribution analysis of afforestation changes in Brazil.

**KEYWORDS:** afforestation, Brazil, Efficient-net, U-net, DeepLab, multispectral

This is an Accepted Manuscript of an article published by Taylor & Francis in Journal of Geocarto International on June 28, 2021, available online:  
<https://www.tandfonline.com/doi/abs/10.1080/10106049.2021.1943009>.

### **INTRODUCTION**

The eucalyptus species are evergreen and belong to the family Myrtaceae, native to Australia and Asia, and can live for a millennium and generally grow in areas surrounded by water. The different species and hybrids of eucalyptus are the hardwood trees with the most prominent global plantation, occurring under different environmental conditions on all continents (Mokochinski et al. 2018). Planted eucalyptus forests have prospered due to: (a) fast-growing species (genetic improvement); (b) greater dependence on the management system than environmental factors (adaptation in tropical, subtropical and temperate regions; (c) monoculture plantation with high turnover and productivity; (d) simplified harvesting and (e) operating at low cost (Payn et al. 2015; Binkley et al. 2020).

Therefore, eucalyptus is a crucial biomass source for producing cellulose and paper pulp, timber and charcoal (Penín et al. 2020).

Currently, Brazil is one of the largest eucalyptus raw materials producers, with the highest annual wood volume produced per area (Associação Brasileira de Árvores 2019; Binkley et al. 2020). The management intensification and genetic improvement (new hybrid clones adapted to environmental factors and pathogens) created shorter harvest cycles, more rapid tree growth and high wood production (McMahon & Jackson 2019). In 2019, the Brazilian planted tree sector reached an annual increase of 12.6% with a planted area of 7.6 million hectares and a contribution of 1.2% in the National Gross Domestic Product (GDP) (Associação Brasileira de Árvores 2020). Therefore, Eucalyptus plantations have changed the rural landscape, influenced urban dynamics and their market grows each year due to the worldwide demand for pulp and paper.

In Brazil, the Brazilian Institute of Geography and Statistics (IBGE) is responsible for annual surveys of planted forests through questionnaires and field research. In this context, remote sensing technologies can efficiently monitor new afforestation areas and assess environmental impacts, considering their high dynamics of changes. Remote sensing data have been different applications in the planted forest sector (Trisasonkho & Paull 2020): forest type mapping, biomass estimation, change detection, plantation age and the detection of invasive species. Different methodologies have been proposed to detect eucalyptus areas using vegetation indices, classifiers and machine-learning methods. The identification of eucalyptus employing vegetation indices such as Normalized Difference Vegetation Index (NDVI), Eucalypt chlorophyll-a reflectance ratio (ECARR) and Eucalypt chlorophyll-b reflectance ratio (ECBRR) have limitations for accurate detection (Baranowski et al. 2020). Classifications based on the eucalyptus spectral signature have used different algorithms: Maximum Likelihood Classification (Goodwin et al. 2005), Support Vector Machines (Sibanda et al. 2021), Feedforward Neural Networks (Forstmaier et al. 2020), AdaBoost and Random Forest (Shang & Chisholm 2014). However, spectral classification (pixel-wise classification) has difficulties for forested areas because of structural complexity (leaf, canopy, or landscape levels) with a high spatial variation of shadow fraction.

Deep Learning (DL) currently achieves state-of-the-art results in computer vision and object detection problems, including remote sensing data (Zhu et al. 2017; Liu et al. 2020). This success is mainly due to advancements in Convolutional Neural Networks (CNNs) (Lecun et al. 1998) since they enable pattern recognition at different levels of data abstraction, ranging from low-level information (corners and edges) to high-level information (complete

objects), generating a refined object delimitation in a high-level understanding of the entire scenario surrounding the target (Nogueira et al. 2017). Besides, CNNs are the most representative in supervised DL models due to the ability to detect and learn highly abstract characteristics, substantially increasing classifiers' performance. CNN is a multilayer architecture containing multiple feature-extraction stages subdivided into three layers: (a) a convolutional layer, (b) a non-linear layer and (c) a pooling layer (Zhang et al. 2016a). Even though there are common stages, there are multiple ways to enhance performance for given tasks (e.g. increasing the number of convolutional layers or using different activation functions). Designing new and effective CNNs is an essential issue in computer vision with various structures being presented over the last few years, such as LeNet (Lecun et al. 1998), VGGNet (Simonyan & Zisserman 2014), GoogLeNet (Szegedy et al. 2015), ResNet (He et al. 2016), ResNeXt (Xie et al. 2017), Efficient-net (Tan & Le 2019), among others.

Several tasks use CNN, such as semantic segmentation, instance segmentation, object detection, among others. For the objective of generating a pixel-wise classification, in which all regions of the image are important, semantic segmentation is the most appropriate alternative. The quality of the semantic segmentation results depends not only on the CNN method but also on the architecture that typically presents an encoder and a decoder section. The encoder is a feature extractor in which different CNN methods may be applied. The decoder is responsible for recovering the image's original dimension, enabling a pixel-wise classification with the same size as the input image. For semantic segmentation, there are various architectures such as the Fully Convolutional Network (FCN) (Zhang et al. 2018), U-net (Ronneberger et al. 2015), DeepLab (Chen et al. 2018), Pyramid Parsing Network (PSPNet) (Long et al. 2015), LinkNet (Chaurasia & Culurciello 2017), Multiscale Attention Net (MANet) (Fan et al. 2020), Feature Pyramid Network (FPN) (Lin et al. 2017), among others.

The semantic segmentation in satellite images has specificities due to its large size and a more significant number of bands, surpassing the usual Red-Green-Blue images (Carvalho et al. 2021). For the processing of large images, the most used technique is the sliding window with a lateral overlay with subsequent reconstruction of the image (Yi et al. 2019; de Bem et al. 2020). The overlapping intervals affect the quality of the reconstructed image, which must be assessed (de Albuquerque et al. 2020). Therefore, DL using CNNs applied in remote sensing has a high potential to contribute to the large-scale analysis of ecosystems and vegetation due to the precise spatial representations of vegetation properties (Brodrick et al. 2019; Kattenborn et al. 2021). This approach provides better results when compared to

traditional machine-learning methods that rely on a per-pixel analysis (Ma et al. 2019). However, currently, the DL is still little explored for the mapping of eucalyptus planted forests.

Thus, this study aims to detect eucalyptus planted forests using Sentinel-2 images and deep semantic segmentation. The research compares six architectures (U-net, DeepLabv3p, PSPNet, LinkNet, MANet and FPN) with four different backbones (ResNet-101, ResNeXt-101-32x8d, Efficient-net-b3 and Efficient-net-b7) using 10 spectral bands. For mapping large images, we evaluated the use of a sliding window technique with different stride values.

## **MATERIAL AND METHODS**

### **STUDY AREA**

The research considered three study areas with a high concentration of planted eucalyptus forests, considering a rectangular region not restricted to the municipal limits (Figure 2.1). The first study area has Teixeira de Freitas in the South BA as its central municipality (3701 eucalyptus plantations), containing a humid tropical climate, landforms ranging from plateaus and mountains to coastal plains and plateaus.

The second study area has its leading economic centre in the city of Aracruz in Northern ES (1065 eucalyptus plantations), containing a humid tropical climate and flat topography (coastal plateau). The last study area is the region led by Telêmaco Borba's municipality in the Centre-East PR (3491 eucalyptus plantations), a pioneer in eucalyptus cultivation in Brazil, with a humid temperate climate and flat to slightly undulating topography (IBGE, 2021; IBGE, 2021). These three regions are all in the Atlantic Forest biome, have edaphoclimatic characteristics suitable for eucalyptus cultivation, and strategic position for transport and export (Cerqueira Neto 2012).

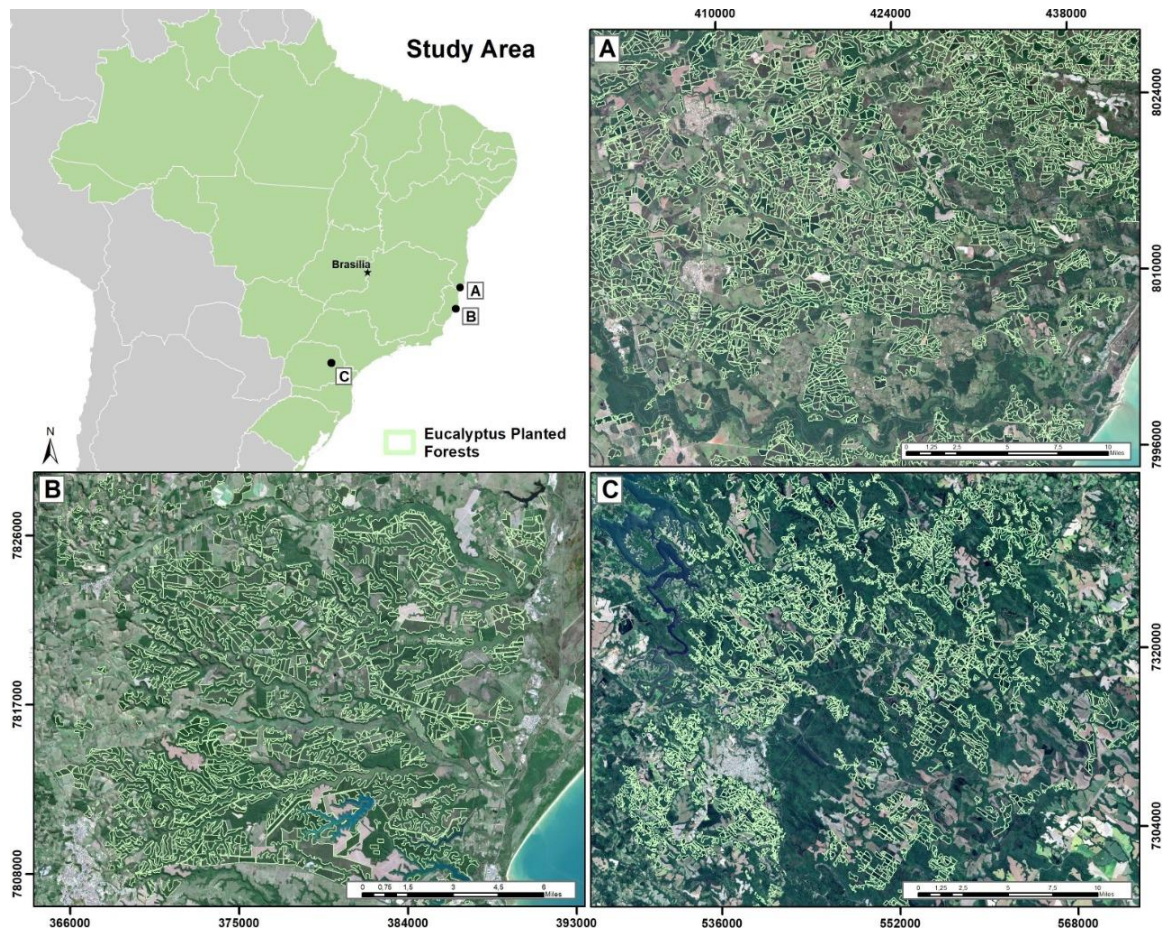


Figure 2.1- Location map of the study areas: (A) Teixeira de Freitas region in the South Bahia, (B) Aracruz region in Northern Espírito Santo, and (C) Telêmaco Borba region in the Center-East Paraná.

### SENTINEL-2 IMAGE, ANNOTATIONS, AND SAMPLE SPLIT

The Sentinel-2 mission under the Copernicus program developed by the Global Monitoring for Environment and Security guarantees the acquisition of high spatial resolution multispectral optical images on terrestrial surfaces (Drusch et al. 2012). The sensor acquires 13 spectral bands distributed in the visible (VIS), near-infrared (NIR) and shortwave infrared (SWIR) in spatial resolutions ranging from 10m (with spectral bands in 490, 560, 665 and 842 nm), 20m (705, 740, 783, 865, 1610 and 2190 nm) and 60m (containing the spectral bands in 443nm for aerosol recovery, 940nm for water vapour correction and 1375nm for cirrus detection). In vegetation mapping studies, the red-edge bands (705, 740 and 783 nm) have distinctive vegetation characteristics, with an application for chlorophyll estimation, leaf area index and vegetation cover distinction.

The acquired images were at Level 1C, with radiometric processing and geometric correction, on the following dates: (1) 19 August 2019 (Teixeira de Freitas); (2) 6 September

2020 (Aracruz) and (3) 13 March 2020 (Telêmaco Borba). In the Sentinel Application Platform (SNAP) software developed by ESA, we perform the following pre-processing:

Table 2.1 - Data split and their respective number of samples and percentages.

Split	Number of samples	Percentage (%)
Train	437	77.76
Validation	64	11.39
Test	61	10.85

(1) atmospheric correction and (2) resampling of pixels to 10m resolution. Therefore, the present research used the 10 spectral bands, where the images originally with 20m resolution were resampled to 10m resolution. Semantic segmentation using all spectral bands achieves greater accuracy than Red-Green-Blue (RGB) channels, the most common approach in the computer vision community (Carvalho et al. 2021). The input data for the semantic segmentation was the set of samples formed by Sentinel-2 images (10 bands) and the respective ground truth mask (binary data), where zero represents the background and one represents the class of interest (eucalyptus plantation). We obtained the ground truth image of eucalyptus plantations from the computer screen's visual interpretation from the composite RGB image. Considering the three study areas, we obtained 562 samples with 160 (height)\_160 (width)\_10 (spectral bands) dimensions distributed as listed in **Table 2.1**.

## DEEP LEARNING MODELS

In order to compare different models for this task, we compared six architectures using the Segmentation Models Pytorch repository (Yakubovskiy 2020): (1) U-net (Ronneberger et al. 2015), (2) DeepLabv3p (Chen et al. 2018), (3) FPN (Lin et al. 2017), (4) MANet (Fan et al. 2020), (5) LinkNet (Chaurasia & Culurciello 2017) and (6) PSPNet (Long et al. 2015).

The U-net, LinkNet, MANet and DeepLabv3p consist of an Encoder-Decoder architecture. The encoder uses a pre-trained CNN (e.g. ResNet), and the decoder restores the image's original dimensions, enabling a pixel-wise classification of a given input image. The U-net uses skip connections with concatenation between the encoder-decoder section, while the LinkNet use skip connections with a summation. The MANet was built upon the U-net, with attention blocks. The DeepLabv3p brings dilated convolutions on the encoder blocks, which increases the field of view of each filter, and uses Atrous Spatial Pyramid Pooling (ASPP) to gather multiscale information. The FPN and PSPNet have intermediate predictions

which help to identify objects with different scale ratios. However, to adapt these networks for semantic segmentation, it is used a decoder with bilinear-upsampling.

Moreover, we evaluated four backbones for each architecture: (1) ResNet-101 (He et al. 2016), (2) ResNeXt-101-32x8d (X-101) (Xie et al. 2017), (3) Efficient-net-b3 (Eff-b3) and (4) Efficient-net-b7 (Eff-b7) (Tan & Le 2019). ResNets use residual blocks that minimize problems such as vanishing gradients, using many convolutional blocks, varying the depth of the networks (e.g., ResNet-50, ResNet-101). The ResNeXts aim to reduce computational cost while still preserving good results by adding cardinality. The Efficient-net is today's state-of-the-art and uses the width, depth, and resolution scaling. There are eight configurations, from Efficient-net-b0 to Efficient-net-b7, in which the increase in complexity improves the results but intensifies the computational cost.

We used the Dice Loss as the loss function and data augmentation in the training procedure, considering random horizontal flip and random vertical flip. Moreover, regarding hyperparameters, we applied: (a) 200 epochs; (b) Adam optimizer; (c) 0.0001 learning rate and (d) 10 batch size. To prevent overfitting, we applied callbacks by saving the models with the best Dice Loss in the validation set.

## SCENE MOSAICKING

Despite the training samples had 160\_160-pixel spatial dimensions, the remote sensing data often requires the inspection of much larger areas. Thus, we implemented mosaicking with a sliding window technique, when the DL algorithm classifies each window pixel with probability outputs (between 0 and 1). The sliding window starts at  $x^{1/40}$  and  $y^{1/40}$ , with a size of 160\_160 pixels and a stride value that establishes an overlapping range. Thus, a 160-pixel stride has no overlap, while smaller values will produce a more extensive overlapping range. The final pixel value will be the average of all overlapping pixel probabilities. Smaller stride values minimize edge errors (de Albuquerque et al. 2020). In this regard, we compared six stride values: 160, 80, 40, 20, 10 and 5 pixels. We applied this procedure to an area with 2080\_1120-pixel dimensions.

## EVALUATION METRICS

### *Training Evaluation*

The evaluation of the test set enables powerful insights into the deployment of the model to practical applications. Most metrics used to compare DL models use the confusion matrix (CM). Nevertheless, the DL models' outputs are values between zero and one, and the CM considers classified elements, being necessary to choose a threshold point. So, all

elements with a value greater than the established threshold value acquire positive labels (1), whereas elements with values less than the established threshold are negative labels (0). Comparing the ground truth with the predictions results in four scenarios: true positives (TP), true negatives (TN), false positives (FP) and false negatives (FN). In our research, we used the conventional 0.5 threshold and evaluated five threshold metrics (**Table 2.2**): overall accuracy (OA), precision (P), recall (R), F-score and Intersection over Union (IoU). Also, we evaluated two ranking metrics: Receiver Operating Characteristic Area Under the Curve (ROC AUC) and the Precision-Recall Area Under the Curve (PR AUC).

### *Mosaic Evaluation*

The mosaic evaluation compared the seven metrics among the six stride values (160, 80, 40, 20, 10, 5 pixels). Since the computational cost significantly increases when decreasing the stride values, it is essential to understand how significant are the advantages of using each stride.

Table 2.2 - Accuracy Metrics and mathematical expressions.

Metric	Equation
Overall Accuracy	$\frac{TP + TN}{TP + TN + FP + FN}$
Precision (P)	$\frac{TP}{TP + FP}$
Recall (R)	$\frac{TP}{TP + FN}$
F-score	$2x \frac{(PxR)}{(P + R)}$
Intersection over Union (IoU)	$\frac{TP}{TP + FN + FP}$

## RESULTS

### METRICS RESULTS

**Table 2.3** list the results for the seven metrics considering the six architectures and four backbones. Considering IoU (the most important metric), DeepLabv3p with Eff-b7 encoder presented the best score.

The U-net, MANet and LinkNet had very close values, with a difference of less than 1% in the IoU metric. The PSPNet and FPN provided the worst results, with an IoU nearly 3% and 2% lower than the DeepLabv3p, respectively. Also, the Eff-b7 backbone presented the top results among all classifiers, while the worst backbone oscillated among the architectures. Regarding the other metrics, the accuracy score was similar among the models,



although it may be misleading since the proportion of classes is imbalanced. Regarding the F-score, the differences were very narrow, but the DeepLabv3p presented the highest score. However, U-net, MANet and LinkNet had higher precision scores. When analyzing the ranking metrics (ROC AUC and PR AUC), the U-net presented the lower ROC AUC and PR AUC, while DeepLabv3p presented the highest scores. Overall, even the worst models presented metrics that are sufficient and efficient for mapping afforestation.

### MOSAICKING RESULTS

**Table 2.4** lists the different stride values in the scene mosaicking procedure using the seven metrics for a testing 2080\_1120 sized image. For all metrics, results progressively increased while reducing the stride value. The ROC AUC increased nearly 1.5% from 160 strides to 5 strides, while the PR AUC increased nearly 4%. Those results are very expressive and show significant improvement using the mosaicking procedure with overlapping pixels. The IoU metric also shows a significant improvement of nearly 2%.

Table 2.3 - Results of accuracy metrics (accuracy (Acc), precision, recall, F-score, IoU, ROC AUC, and PR AUC) for the six architectures (U-net, FPN, DeepLabv3+, MANet, LinkNet, and PSPNet) and four backbones (Eff-b7, Eff-b3, R-101, and X-101).

<b>Unet</b>							
	<b>Acc</b>	<b>Precision</b>	<b>Recall</b>	<b>F-score</b>	<b>IoU</b>	<b>ROC</b>	<b>PR</b>
<b>Eff-b7</b>	90.86	83.05	90.29	86.52	76.24	92.44	85.15
<b>Eff-b3</b>	90.05	81.15	90.38	85.52	74.70	92.86	84.60
<b>R-101</b>	89.55	80.49	89.56	84.78	73.59	92.33	83.06
<b>X-101</b>	89.77	81.21	89.16	85.00	73.91	91.83	81.98
<b>FPN</b>							
<b>Eff-b7</b>	90.26	81.94	89.82	85.7	74.97	95.06	87.70
<b>Eff-b3</b>	89.74	81.68	88.22	84.82	73.65	94.87	88.72
<b>R-101</b>	89.42	82.63	85.41	84.00	72.41	93.72	86.99
<b>X-101</b>	89.29	80.91	87.75	84.19	72.70	93.32	84.94
<b>DeepLabv3+</b>							
<b>Eff-b7</b>	90.93	82.66	91.23	86.73	76.57	95.93	89.65
<b>Eff-b3</b>	89.72	81.24	88.88	84.89	73.74	93.5	84.93
<b>R-101</b>	89.75	82.64	86.66	84.6	73.32	93.16	86.53
<b>X-101</b>	89.45	80.95	88.33	84.48	73.12	94.28	88.94
<b>MANet</b>							
<b>Eff-b7</b>	90.86	83.07	90.26	86.51	76.23	93.74	85.76
<b>Eff-b3</b>	90.49	83.22	88.61	85.83	75.18	92.94	85.48

<b>R-101</b>	89.70	81.26	88.76	84.85	73.68	92.19	82.46
<b>X-101</b>	90.05	81.77	89.28	85.36	74.46	93.18	87.21
<b>LinkNet</b>							
<b>Eff-b7</b>	90.70	82.68	90.29	86.32	75.93	95.08	88.46
<b>Eff-b3</b>	90.58	83.46	88.58	85.94	75.35	94.81	89.61
<b>R-101</b>	90.34	83.89	86.98	85.41	74.53	91.89	83.12
<b>X-101</b>	90.49	82.61	89.58	85.96	75.37	92.69	83.63
<b>PSPNet</b>							
<b>Eff-b7</b>	89.80	81.40	88.92	85.00	73.91	94.51	87.34
<b>Eff-b3</b>	88.49	78.72	88.52	83.33	71.43	93.84	87.07
<b>R-101</b>	89.06	79.80	88.82	84.07	72.52	94.89	88.08
<b>X-101</b>	89.12	80.00	88.71	84.13	72.61	94.79	87.92

Table 2.4 - Accuracy metrics for mosaicking using 6 different stride values.

<b>Stride</b>	<b>Acc</b>	<b>Precision</b>	<b>Recall</b>	<b>F-score</b>	<b>IoU</b>	<b>ROC</b>	<b>PR</b>
<b>5</b>	93.54	86.69	94.04	90.22	82.18	98.36	95.96
<b>10</b>	93.39	86.34	94.00	90.01	81.83	98.25	95.7
<b>20</b>	93.28	86.21	93.78	89.83	81.54	98.13	95.35
<b>40</b>	93.25	86.20	93.69	89.79	81.47	98.04	95.05
<b>80</b>	93.07	85.94	93.39	89.51	81.01	97.79	94.33
<b>160</b>	92.65	85.27	92.82	88.89	79.99	97.01	92.35

**Figure 2.2** shows the original 2080\_1120 image, the ground truth mask and the DL prediction using DeepLabv3p with the Eff-b7 encoder in the 10-band image and 5-pixel stride value using a threshold of 0.5 and the probabilistic prediction. The prediction shows values ranging from 0 to 1, in which the more confident pixels (closer to one or zero) are yellow and black, and the values in between are in different tones of blue. Most areas have high confidence shown by the yellow colour, and the results show very close to the ground truth, showing a good prediction.


**Figure 2.3** shows two situations in detail (zoom areas) for improving the DL estimate by decreasing the stride value. **Figure 2.3A** and **B** demonstrates that the detection of an actual eucalyptus forest gradually improves with a decrease in value. Therefore, these examples show how the mosaicking algorithm may enhance border errors making the adjacent frame predictions smooth, increasing metrics and visualization. Semantic segmentation achieved an excellent result in distinguishing between eucalyptus forests and natural vegetation, especially gallery forests. These characteristics make the method very efficient in mapping afforestation.

## DISCUSSION


In the global market, planted forest monitoring systems play an essential role in decisionmaking processes and regional development planning. The spatial distribution and growth dynamics of planted forests are fundamental for establishing global and national strategies aimed at social, ecological and economic development. In Brazil, the IBGE conducts the census of planted forests through household surveys, which are expensive and require a lot of fieldwork and time. Furthermore, monitoring eucalyptus production in Brazil is a challenge due to its continental size with different topographic and climatic conditions. Therefore, remote sensing techniques are advantageous for monitoring planted forest areas, providing geolocation information and area dimensions with less cost and time.

The detection of natural and planted forests by remote sensing is a challenge due to the canopy's complexity, illumination geometry and shadow variability in the forest environment. In the afforestation area, the planted trees in row arrangements generate canopy gaps in plantations that cause heterogeneity in the spectral response, increasing the reflectance variation (Trisasongko & Paull 2020). The high-resolution Sentinel-2 image highlights the intra-canopy and inter-canopy shading, decreasing the detection between different forest coverages with pixel-based classifiers. Shang and Chisholm (2014) pointed out limitations in mapping forests from different algorithms (Support Vector Machine, AdaBoost, Random Forest and Linear Discriminant Analysis) using only spectral information, suggesting the addition of textural measures. In contrast to these approaches, deep learning techniques have recently demonstrated a high ability to automatically extract and learn feature representations in complex, subtle and abstract contexts, surpass traditional methods and achieve state-of-the-art. Despite the revolution in deep learning using CNNs in remote sensing (Zhang et al. 2016; Ma et al. 2019), studies on its application in mapping planted forests using remote sensing data are still lacking.


Original Image



Ground Truth



Prediction with 0.5 threshold



Prediction with probabilities




Figure 2.2- Example of entire scene mosaicking in a 2080x1120-pixel area, with the original image, the ground truth (GT), and the DeepLabv3+ with Efficient-net-b7 (Eff-b7) encoder prediction.

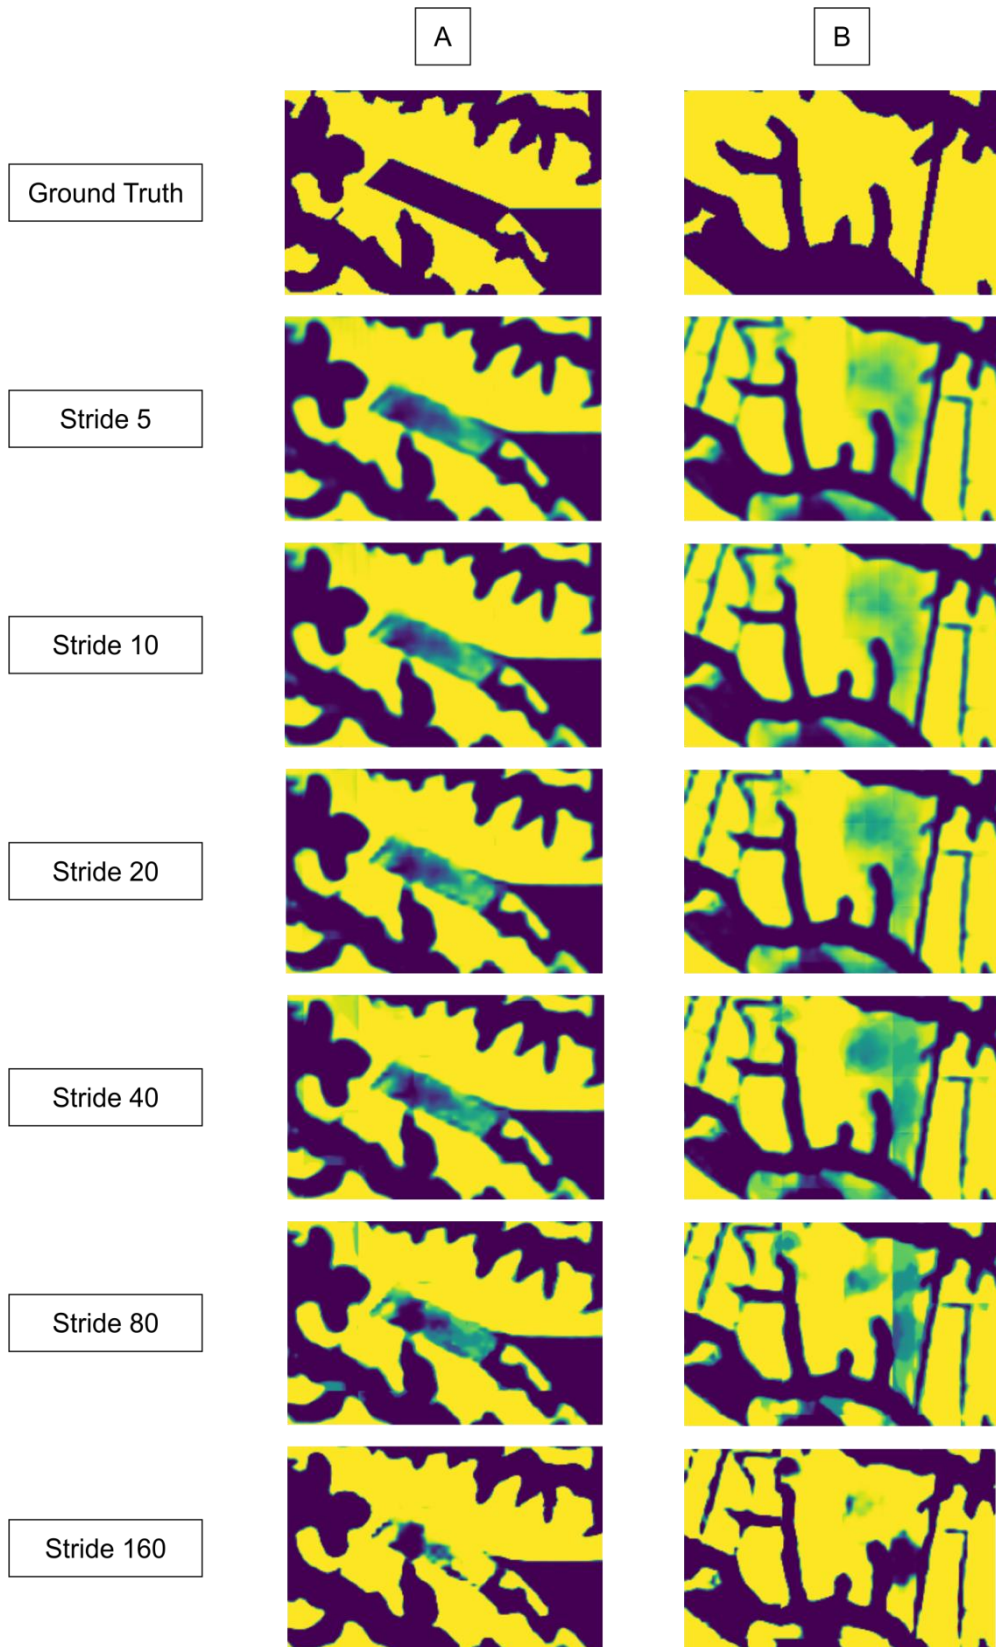


Figure 2.3-Representation of two examples, in which the first (A) shows the appearance of an object by decreasing the stride, and the second (B) the disappearance by decreasing the stride.

The present research used pixel-wise semantic segmentation with six architectures (Unet, DeepLabv3p, FPN, MANet, PSPNet, LinkNet) with four encoders (ResNet-101, ResNeXt-101, Efficient-net-b3 and Efficient-net b7). The best model was the model that combines DeepLabv3p with Efficient-net-B7. The results demonstrate that the Efficientnet-B7 backbone presents better precision and efficiency than the other ConvNets for all tested architectures, confirming the results of Tan and Le (2019). As a recent backbone, Efficient-net-B7 is still little explored in remote sensing data, but it presents a growth perspective (Hoeser & Kuenzer 2020).

The semantic segmentation of remote sensing images differs from traditional images due to their larger dimensions. Although the training stage uses a smaller sample size, the segmentation result must be the original image's size, which is often much more extensive. The most used solution is the mosaic of the segmented frames obtained by a sliding window with the same training sample size. Windows can have an overlap area, and its average values reduce the impact of edge errors (Yi et al. 2019; de Bem et al. 2020; Carvalho et al. 2021) . The frame border concentrates errors in CNN segmentation because it does not have the entire object. In this context, de Albuquerque et al. (2020) and Costa et al. (2021) tested different stride values in the horizontal and vertical directions, noting that the greater the overlapping range, the greater the minimization of edge errors. The results also demonstrate the importance of this procedure to eliminate edge errors, which appear both by omission and commission.

The present study also uses semantic segmentation with 10 Sentinel-2 channels, differing from most CNN searches that restrict RGB channels. According to Carvalho et al. (2021), the use of different spectral bands favours the detection of remote sensing targets. Specifically, in forest areas, the red-edge channels' insertion allows more information about the vegetation characteristics.

## **CONCLUSION**

The present study innovates in the identification of eucalyptus forest plantations using CNN methods. The research compared 24 DL models based on combinations between six architectures (U-net, DeepLabv3p, FPN, MANet, PSPNet, LinkNet) and four encoders (ResNet-101, ResNeXt-101, Efficient-net-b3 and Efficient-net-b7). The processing of the Sentinel-2 images considered ten spectral bands and the sliding window method for classifying large scenes. The best model was DeepLabv3p architecture and Eff-b7 encoder, presenting an IoU metric of 76.57. The Eff-b7 backbone obtained the best result among all the

evaluated architectures. The mosaic using a sliding window with low stride values proved to be a fundamental step in this type of target, significantly decreasing the edge error evidenced in both the ROC and PR scores. Therefore, the present study demonstrates the DL method's efficiency in mapping eucalyptus plantations in large areas, being an important alternative for the data acquisition aiming at territorial planning and development.

## REFERENCES

- Associação Brasileira de Árvores 2019. Brazilian Tree Industry Annual Report 2019. Brasília, Federal District, Brazil. <https://www.iba.org/datafiles/publicacoes/relatorios/iba-relatorioanual2019.pdf>.
- Associação Brasileira de Árvores 2020. Brazilian Tree Industry Annual Report 2020. Brasília, Federal District, Brazil. <https://iba.org/datafiles/publicacoes/relatorios/relatorio-iba-2020.pdf>.
- Baranowski K, Taylor T, Lambert B, Bharti N. 2020. Application of reflectance ratios on high-resolution satellite imagery to remotely identify eucalypt vegetation. *Remote Sens.* 12(24):4079.
- Binkley D, Campoe OC, Alvares CA, Carneiro RL, Stape JL. 2020. Variation in whole-rotation yield among Eucalyptus genotypes in response to water and heat stresses: the TECHS project. *For Ecol Manage.* 462:117953.
- Brodrick PG, Davies AB, Asner GP. 2019. Uncovering ecological patterns with convolutional neural networks. *Trends Ecol Evol.* 34(8):734–745.
- Carvalho O. d, de Carvalho Junior OAA, Albuquerque AO, de Bem PP, de Silva CR, Ferreira PHG, de Moura RdS, Gomes RAT, Guimarães RF, Borges DL. 2020. Instance segmentation for large, multi-channel remote sensing imagery using Mask-RCNN and a mosaicking approach. *Remote Sens.* 13(1):39.
- Cerqueira Neto SPG. 2012. Três décadas de eucalipto no extremo sul da Bahia. *GEOUSP – Espaço e Tempo.* 31:55–68.
- Chaurasia A, Culurciello E. 2017. LinkNet: Exploiting encoder representations for efficient semantic segmentation. In: 2017 IEEE Vis Commun Image Process. Vol. 2018 [place unknown]. Piscataway, NJ: IEEE; p. 1–4. <http://ieeexplore.ieee.org/document/8305148/>.
- Chen LC, Papandreou G, Kokkinos I, Murphy K, Yuille AL. 2018. DeepLab: semantic image segmentation with deep convolutional Nets, Atrous convolution, and fully connected CRFs. *IEEE Trans Pattern Anal Mach Intell.* 40(4):834–848.
- Da Costa MVCV, de Carvalho OLF, Orlandi AG, Hirata I, De Albuquerque AO, e Silva FV, Guimarães RF, Gomes RAT, de Junior OAC. 2021. Remote sensing for monitoring photovoltaic solar plants in Brazil using deep semantic segmentation. *Energies.* 14(10):2960.
- de Albuquerque AO, de Carvalho OLF, e Silva CR, de Bem PP, Trancoso Gomes RA, Borges DL, Guimarães RF, Pimentel CMM, de Carvalho Junior OA. 2021. Instance segmentation of center pivot irrigation systems using multi-temporal SENTINEL-1 SAR images. *Remote Sens Appl Soc Environ.* 23: 100537

- de Albuquerque AO, de Carvalho Junior OA, Carvalho OLF, de Bem PP, Ferreira PHG, de Moura RdS, Silva CR, Trancoso Gomes RA, Fontes Guimarães R. 2020. Deep semantic segmentation of center pivot irrigation systems from remotely sensed data. *Remote Sens.* 12(13):2159.
- de Bem PP, de Carvalho Junior OAA, de Carvalho OLF, Gomes RAT, Fontes Guimarães R, Guimarães RF. 2020. Performance analysis of deep convolutional autoencoders with different patch sizes for change detection from burnt areas. *Remote Sens.* 12(16):2576.
- Drusch M, Del Bello U, Carlier S, Colin O, Fernandez V, Gascon F, Hoersch B, Isola C, Laberinti P, Martimort P, et al. 2012. Sentinel-2: ESA's optical high-resolution mission for GMES operational services. *Remote Sens Environ.* 120:25–36
- Fan T, Wang G, Li Y, Wang H. 2020. Ma-net: a multi-scale attention network for liver and tumor segmentation. *IEEE Access.* 8:179656–179665.
- Forstmaier A, Shekhar A, Chen J. 2020. Mapping of eucalyptus in Natura 2000 areas using Sentinel 2 imagery and artificial neural networks. *Remote Sens.* 12(14):2176.
- Goodwin N, Turner R, Merton R. 2005. Classifying Eucalyptus forests with high spatial and spectral resolution imagery: an investigation of individual species and vegetation communities. *Aust J Bot.* 53(4):337.
- He K, Zhang X, Ren S, Sun J. 2016. deep residual learning for image recognition. In: 2016 IEEE Conf Comput Vis Pattern Recognit. Vol. 45. Las Vegas, NV, USA. Piscataway, NJ: IEEE; p. 770–778. <http://ieeexplore.ieee.org/document/7780459/>.
- Hoeser T, Kuenzer C. 2020. Object detection and image segmentation with deep learning on earth observation data: a review-part I: evolution and recent trends. *Remote Sens.* 12(10):1667.
- [IBGE] Instituto Brasileiro de Geografia e Estatística. 2002. Mapa de clima do Brasil. [accessed 2021 Mar 24]. <http://mapas.ibge.gov.br/tematicos.html>.
- [IBGE] Instituto Brasileiro de Geografia e Estatística. 2006. Unidades de Relevo 1:5.000.000 j 2006. [accessed 2021 Mar 24]. <https://www.ibge.gov.br/geociencias/informacoes-ambientais/geomorfologia/15827-unidades-de-relevo.html?=&t=downloads>.
- Kattenborn T, Leitloff J, Schiefer F, Hinz S. 2021. Review on Convolutional Neural Networks (CNN) in vegetation remote sensing. *ISPRS J Photogramm Remote Sens.* 173:24–49.
- Lecun Y, Bottou L, Bengio Y, Haffner P. 1998. Gradient-based learning applied to document recognition. *Proc IEEE.* 86(11):2278–2324.
- Lin T-Y, Dollar P, Girshick R, He K, Hariharan B, Belongie S. 2017. Feature pyramid networks for object detection. In: 2017 IEEE Conf Comput Vis Pattern Recognit. Honolulu, HI, USA. Piscataway, NJ: IEEE; p. 936–944. <http://arxiv.org/abs/1612.03144>.
- Liu L, Ouyang W, Wang X, Fieguth P, Chen J, Liu X, Pietikainen M. 2020. Deep learning for generic object detection: a survey. *Int J Comput Vis.* 128(2):261–318.
- Long J, Shelhamer E, Darrell T. 2015. Fully convolutional networks for semantic segmentation. In: 2015 IEEE Conference on Computer Vision and Pattern Recognition



(CVPR). p. 3431–3440.

Ma L, Liu Y, Zhang X, Ye Y, Yin G, Johnson BA. 2019. Deep learning in remote sensing applications: A meta-analysis and review. *ISPRS J Photogramm Remote Sens.* 152:166–177.

McMahon DE, Jackson RB. 2019. Management intensification maintains wood production over multiple harvests in tropical Eucalyptus plantations. *Ecol Appl.* 29(4):e01879.

Mokochinski JB, Mazzafera P, Sawaya ACHF, Mumm R, de Vos RCH, Hall RD. 2018. Metabolic responses of Eucalyptus species to different temperature regimes. *J Integr Plant Biol.* 60(5):397–411.

Nogueira K, Penatti OAB, dos Santos JA. 2017. Towards better exploiting convolutional neural networks for remote sensing scene classification. *Pattern Recognit.* 61:539–556.

Payn T, Carnus JM, Freer-Smith P, Kimberley M, Kollert W, Liu S, Orazio C, Rodriguez L, Silva LN, Wingfield MJ. 2015. Changes in planted forests and future global implications. *For Ecol Manage.* 352: 57–67.

Penin L, Lopez M, Santos V, Alonso JL, Parajo JC. 2020. Technologies for Eucalyptus wood processing in the scope of biorefineries: a comprehensive review. *Bioresour Technol.* 311:123528.

Ronneberger O, Fischer P, Brox T. 2015. U-Net: convolutional networks for biomedical image segmentation. In: Navab N, Hornegger J, Wells W, Frangi A, editors. *Lect Notes Comput Sci (including Subser Lect Notes Artif Intell Lect Notes Bioinformatics)*. Vol. 9351. Cham: Springer; p. 234–241. [http://link.springer.com/10.1007/978-3-319-24574-4\\_28](http://link.springer.com/10.1007/978-3-319-24574-4_28).

Shang X, Chisholm LA. 2014. Classification of Australian native forest species using hyperspectral remote sensing and machine-learning classification algorithms. *IEEE J Sel Top Appl Earth Observ Remote Sens.* 7(6):2481–2489.

Sibanda M, Buthelezi S, Ndlovu HS, Mothapo MC, Mutanga O. 2021. Mapping the Eucalyptus spp. woodlots in communal areas of Southern Africa using Sentinel-2 Multi-Spectral Imager data for hydrological applications. *Phys Chem Earth.* 122:102999.

Simonyan K, Zisserman A. 2014. Very deep convolutional networks for large-scale image recognition. <http://arxiv.org/abs/1409.1556>.

Szegedy C, Wei L, Yangqing J, Sermanet P, Reed S, Anguelov D, Erhan D, Vanhoucke V, Rabinovich A. 2015. Going deeper with convolutions. In: 2015 IEEE Conf Comput Vis Pattern Recognit. Vol. 91. [place unknown]. Piscataway, NJ: IEEE; p. 1–9. <http://ieeexplore.ieee.org/document/7298594/>.

Tan M, Le QV. 2019. EfficientNet: rethinking model scaling for convolutional neural networks. arXiv. arxiv:1905.11946

Trisasongko BH, Paull D. 2020. A review of remote sensing applications in tropical forestry with a particular emphasis in the plantation sector. *Geocarto Int.* 35(3):317–339.

Xie S, Girshick R, Dollar P, Tu Z, He K. 2017. Aggregated Residual Transformations for Deep Neural Networks. In: 2017 IEEE Conf Comput Vis Pattern Recognit. Honolulu, HI, USA. Piscataway, NJ: IEEE; p. 5987–5995. <https://github.com/facebookresearch/ResNeXt%0Ahttp://arxiv.org/abs/1611.05431v2>

Yakubovskiy P. 2020. Segmentation Models Pytorch. GitHub Repos

Yi Y, Zhang Z, Zhang W, Zhang C, Li W, Zhao T. 2019. Semantic segmentation of urban buildings from VHR remote sensing imagery using a deep convolutional neural network. *Remote Sens.* 11(15):1774.

Zhang Y, Qiu Z, Yao T, Liu D, Mei T. 2018. Fully Convolutional adaptation networks for semantic segmentation. *Proc IEEE Comput Soc Conf Comput Vis Pattern Recognit.* 6810–6818.

Zhang L, Zhang L, Du B. 2016. Deep learning for remote sensing data: a technical tutorial on the state of the art. *IEEE Geosci Remote Sens Mag.* 4(2):22–40

Zhu XX, Tuia D, Mou L, Xia G, Zhang L, Xu F, Fraundorfer F. 2017. Deep Learning in Remote Sensing: A Comprehensive Review and List of Resources. *IEEE Geosci Remote Sens Mag.* 5(4):8–36.

## **CAPÍTULO 3 - CONCLUSÃO**

O eucalipto é uma espécie altamente resistente e com fácil adaptação em diferentes condições ambientais, características estas que promoveram sua introdução na economia brasileira. Suas florestas plantadas possuem grande importância econômica, resultado de constante melhoramento genético e inovação nas técnicas avançadas de silvicultura, que colaboram com seu rápido crescimento, alta produtividade, alta rotatividade, colheita simplificada e baixo custo de operação. As florestas plantadas de eucalipto também influenciam na paisagem rural, transformando e influenciando a dinâmica urbana e seu mercado cresce todos os anos por conta da alta demanda dos produtos derivados de seus insumos.

O monitoramento de florestas plantadas é essencial para a economia e para a criação de políticas no Brasil. As florestas plantadas de Eucalipto atuam na redução da pressão sobre florestas naturais e se tornaram relevantes na economia, na sociedade e no meio ambiente. O sensoriamento remoto atua no monitoramento de áreas plantadas, na avaliação de impactos ambientais, no mapeamento de florestas, na estimativa de biomassa, na detecção de mudanças, na estimativa da idade de plantações e na detecção de espécies invasoras. O monitoramento por meio de sensoriamento remoto diminui os custos e a mão de obra, dando agilidade e maior precisão na gestão e análise de dados.

As técnicas atuais de sensoriamento remoto para monitoramento de florestas possuem alguns problemas nos procedimentos de índices de vegetação, dos classificadores e nas técnicas de Machine Learning, com dificuldades de classificação de áreas de florestas pela complexidade estrutural, com alta variação espacial de frações de sombra e pela precisão limitada dos resultados. Como solução estudamos as Redes Neurais Convolucionais (CNN) para encontrar uma técnica mais avançada, ágil e precisa nos resultados de monitoramento de florestas plantadas.

O presente estudo inova na identificação de plantações de florestas de eucalipto por meio de métodos de CNN, que é um método pouco utilizado para análises de florestas por meio de imagens de satélite, por serem imagens de áreas grandes.

Escolhemos utilizar as imagens Sentinel-2 para estudar três áreas com alta concentração de florestas plantadas de eucalipto: (1) Teixeira de Freitas, no estado da Bahia; (2) Aracruz, no estado de Espírito Santo; e (3) Telêmaco Borba, no estado do Paraná. As imagens Sentinel-2 são imagens gratuitas, o que facilita no desenvolvimento desta técnica de monitoramento de áreas de florestas plantadas sem necessidade gerar grandes custos para sua execução.

A presente pesquisa comparou 24 modelos de Deep Learning com base em combinações entre seis arquiteturas (U-net, DeepLabv3 +, FPN, MANet, PSPNet, LinkNet) e quatro codificadores (ResNet-101, ResNeXt-101, Efficient-net-b3 e Efficient-net-b7). O processamento das imagens do Sentinel-2 considerou 10 bandas espectrais (excluindo-se apenas as bandas relacionadas à atmosfera) e o método da janela deslizante para classificar grandes áreas.

O melhor modelo foi a arquitetura DeepLabv3 + com o codificador Eff-b7, apresentando uma métrica IoU de 76,57. O codificador Eff-b7 obteve o melhor resultado entre todas as arquiteturas avaliadas. Ainda que este resultado tenha sido o melhor entre todas as arquiteturas avaliadas, todas as outras combinações deram bons resultados para as métricas avaliadas, mostrando que a utilização de CNNs para a identificação de florestas plantadas de eucalipto obteve resultados bastante precisos conforme as máscaras da verdade.

O mosaico em janela deslizante com baixos valores de passadas mostrou-se uma etapa fundamental neste tipo de alvo, diminuindo significativamente o erro de borda, evidenciado tanto nas pontuações da Curva ROC quanto nas pontuações de Precisão-Sensibilidade.

Portanto, o presente estudo demonstra a eficiência do Deep Learning, com uso de CNNs, no mapeamento de florestas plantadas de eucalipto em grandes áreas, por meio de imagens Sentinel-2, sendo uma alternativa importante para a aquisição de dados visando o planejamento e desenvolvimento territorial.

Os resultados deste trabalho levantaram questões para novas possibilidades de estudos futuros dentro desta temática. Foram questões levantadas:

- (1) Esta metodologia de uso de CNNs para classificação em imagens de sensoriamento remoto entrega resultados diferentes entre as três áreas estudadas. Uma comparação entre os resultados das métricas entre áreas poderá demonstrar se alguma região de estudo teve maior eficiência na em relação às outras?
- (2) Esta metodologia de classificação com uso de CNNs em imagens de sensoriamento remoto seria uma alternativa para identificar diferentes tipos de espécies de eucalipto entre si de forma automática?
- (3) Atualmente, as técnicas de Deep Learning se mostram muito eficazes na classificação de imagens em geral e de imagens por sensoriamento remoto, mostrando que as arquiteturas dessas redes já estão bem desenhadas para estabelecer resultados com alta precisão. Por isso, notou-se a importância de um estudo de técnicas mais precisas na obtenção de dados de sensoriamento remoto para alimentar as CNNs, de forma que a precisão na classificação seja ainda

melhor.

Este trabalho gerou uma publicação de título “Deep Semantic Segmentation for Detecting Eucalyptus Planted Forests in the Brazilian Territory Using Sentinel-2 Imagery”, publicado na revista Geocarto International, da editora Taylor & Francis Group, em 28 de junho de 2021.