

**UNIVERSIDADE FEDERAL DO MATO GROSSO DO
SUL
CAMPUS CAMPO GRANDE
FACULDADE DE COMPUTAÇÃO
BACHARELADO EM ENGENHARIA DE COMPUTAÇÃO**

Maria Eduarda de Paula Duarte

Análise com auxílio da inteligência artificial para a plantação de eucalipto

CAMPO GRANDE
2025

Maria Eduarda de Paula Duarte

Análise com auxílio da inteligência artificial para a plantação de
eucalipto

Trabalho de Conclusão de Curso
apresentado ao Curso de Ba-
charelado em Engenharia de
Computação da Universidade Fede-
ral de Mato Grosso do Sul, Campus
Campo Grande, como requisito
parcial para obtenção do título
de Bacharel em Engenharia de
Computação.

Linha de Pesquisa: Inteligência arti-
ficial

Orientador(a): Wesley Nunes Gon-
calves

CAMPO GRANDE
2025

Maria Eduarda de Paula Duarte

Análise com auxílio da inteligência artificial para a plantação de
eucalipto

Trabalho de Conclusão de Curso apresentado ao Curso de
Bacharelado em Engenharia de Computação da Universidade Federal
do Mato Grosso do Sul, Campus Campo Grande, Faculdade de
computação, como requisito parcial para obtenção do título de
Bacharel em Engenharia de Computação.

Linha de Pesquisa: Inteligência artificial

Orientador(a): Wesley Nunes Gonçalves

BANCA EXAMINADORA

Wesley Nunes Gonçalves
Universidade Federal do Mato Grosso do Sul (UFMS)
UFMS | Campus Campo Grande

Maximilian Jaderson De Melo
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso
do Sul (IFMS)
IFMS | Campus Naviraí

Wesley Eiji Sanches Kanashiro
Instituto Federal de Educação, Ciência e Tecnologia de Mato Grosso
do Sul (IFMS)
IFMS | Campus Campo Grande

CAMPO GRANDE, 31 DE OUTUBRO DE 2025.

Resumo

O cultivo de eucalipto é fundamental para o setor florestal brasileiro, pela alta produtividade, rápido crescimento e importância econômica na produção de papel, celulose e energia. A estimativa da produtividade depende da contagem precisa de plantas, que atualmente é realizada de forma manual e amostral, resultando em maior custo e suscetível a erros. Este trabalho propõe uma metodologia automatizada baseada em deep learning e imagens de drones para realizar a contagem de eucaliptos. As plantas foram anotadas por meio de pontos centrais e, para permitir a aplicação de técnicas de segmentação, essas anotações foram dilatadas com diferentes raios (r). A metodologia contemplou o pré-processamento das imagens, o treinamento de modelos de segmentação semântica e a avaliação por métricas de desempenho, como precisão, recall, F1-score e análise de erros. Os resultados mostraram que dilatações intermediárias (entre $r = 5$ e $r = 11$) alcançaram melhor equilíbrio entre precisão e recall, fornecendo estimativas mais confiáveis da quantidade de plantas. Assim, a abordagem demonstrou viabilidade prática para o manejo florestal, configurando-se como alternativa promissora para automatizar a contagem de mudas de eucalipto e otimizar o monitoramento da produtividade.

Palavras-chave: Monitoramento de plantação de eucalipto. Segmentação semântica. Deep learning.

Abstract

Eucalyptus cultivation plays a key role in the Brazilian forestry sector due to its high productivity, fast growth, and economic importance, especially in the production of paper, cellulose, and energy. Estimating productivity requires an accurate count of plants, which is currently performed manually and through sampling, a process that is costly and prone to errors. This study proposes an automated methodology based on deep learning and drone imagery to count eucalyptus trees. Plants were annotated using central points, which were then dilated with different radii (r) to enable the application of segmentation techniques. The methodology encompassed image preprocessing, semantic segmentation model training, and evaluation using performance metrics such as precision, recall, F1-score, and error analysis across different dilation levels. Results showed that intermediate dilations (between $r = 5$ and $r = 11$) achieved the best balance between precision and recall, providing more reliable estimates of plant counts. Therefore, the proposed approach demonstrated practical feasibility for forest management, offering a promising alternative to automate eucalyptus seedling counting and improve productivity monitoring.

Keywords: Eucalyptus plantation monitoring, Semantic segmentation, Deep learning

Sumário

Lista de Figuras	6
Lista de Tabelas	7
1 Introdução	9
2 Objetivos geral e específico	10
3 Trabalhos correlatos	10
4 Materiais e métodos	12
4.1 Coleta de dados	12
4.1.1 Anotação do conjunto de dados (dot supervision)	13
4.1.2 Vantagens e limitações.	13
4.2 Pré-processamento	14
4.3 Ambiente computacional e configuração dos experimentos	14
4.4 Treinamento dos modelos	16
4.5 Pós-processamento e contagem	16
5 Experimentos e resultados	17
5.1 Resultados Quantitativos	17
5.2 Resultados Qualitativos	20
5.3 Impacto Prático no Campo	21
6 Conclusão	22
Referências	23

Lista de Figuras

1	Exemplo ilustrativo do processo de dilatação das anotações pontuais. À esquerda, as mudas são representadas por pontos centrais. À direita, observa-se a conversão desses pontos em regiões circulares (máscaras binárias) com diferentes raios de dilatação ($r = 3, 11, 21$), utilizadas como rótulos para o treinamento dos modelos.	15
2	Relação entre os valores de alpha e a Precisão para diferentes dilatações.	17
3	Relação entre os valores de alpha e a recall.	18
4	Relação entre os valores de alpha e o F1-Score.	18
5	Exemplo 1: Planta existente marcada.	20
6	Exemplo 1: Planta existente marcada.	20
7	Exemplo 2: Planta não existente não marcada.	20
8	Exemplo 2: Planta não existente não marcada.	20
9	Exemplo 3: Planta existente não marcada.	21
10	Exemplo 3: Planta existente não marcada.	21
11	Exemplo 4: Planta existente marcada.	21
12	Exemplo 4: Planta existente marcada.	21

Lista de Tabelas

- 1 Métricas de Precisão (P), recall (R) e F1 em diferentes valores de dilatação (r), organizadas por $\alpha = 10$ e $\alpha = 70$ 19

Lista de Abreviações e Siglas

GPU Unidade de Processamento Gráfico. 14

GSD Ground Sampling Distance. 12

IA Inteligência Artificial. 9

ITD Individual Tree Detection. 11

RGB Red, Green, Blue. 12

1 Introdução

O cultivo de eucalipto no Brasil tem se consolidado como uma das principais estratégias para o suprimento sustentável de matéria-prima florestal, desempenhando papel relevante na economia e no setor industrial, especialmente na produção de papel, celulose e energia. De acordo com a Klabin, uma das maiores empresas do ramo, o eucalipto alia rápido crescimento, alta produtividade e versatilidade de uso, tornando-se uma alternativa viável para reduzir a pressão sobre florestas nativas. Nesse cenário, compreender os desafios e as oportunidades ligados ao reflorestamento com eucalipto é essencial para promover práticas equilibradas, capazes de conciliar desenvolvimento econômico e preservação ambiental. Além de seu valor econômico, o eucalipto ocupa posição estratégica na geração de emprego, renda e no fornecimento sustentável de matéria-prima para diferentes cadeias produtivas.

Para estimar a produtividade dessas plantações, é fundamental a contagem precisa das mudas. Atualmente, esse processo é realizado de forma manual e amostral, com trabalhadores percorrendo apenas trechos da área cultivada e extrapolando os resultados para o restante. Esse método, além de ser lento e oneroso, gera apenas estimativas e está sujeito a erros significativos, o que compromete tanto o planejamento quanto o manejo florestal.

Nesse contexto, o avanço das tecnologias digitais tem aberto novas possibilidades para a modernização do setor, em especial com o uso de inteligência artificial. A aplicação da Inteligência Artificial (IA) no monitoramento de florestas, por meio da contagem automatizada de mudas e do acompanhamento do crescimento das plantas, permite maior precisão, agilidade e redução de custos operacionais.

No Brasil, a relevância econômica e territorial do eucalipto é expressiva. Em 2023, as florestas plantadas totalizaram cerca de 9,9 milhões de hectares, das quais aproximadamente 7678% são de eucalipto (~7,6 milhões de hectares), consolidando-se como a espécie mais cultivada no país [Indústria Brasileira de Árvores (Ibá), 2023, IBGE and Agência IBGE Notícias, 2025]. Em termos econômicos, o segmento de silvicultura respondeu por R\$ 44,3 bilhões em 2024, reforçando o papel do setor na indústria de celulose, papel e energia [IBGE and Agência IBGE Notícias, 2025]. Esses números, consistentes com séries históricas e avaliações internacionais [FAO, 2020], contextualizam a importância prática de metodologias automatizadas para contagem e monitoramento de plantios de eucalipto.

Diante desse cenário, este trabalho propõe uma metodologia inovadora para automatizar a contagem de mudas de eucalipto, combinando imagens aéreas obtidas por drones e modelos de deep learning baseados em segmentação semântica. As plantas foram anotadas a partir de pontos centrais, posteriormente dilatados em diferentes raios para permitir a aplicação dos algoritmos de segmentação. As análises

foram conduzidas em talhões de eucalipto em estágio inicial de crescimento, com mudas medindo aproximadamente 30 a 50 cm de altura, faixa na qual o delineamento individual das copas é mais evidente nas imagens aéreas. Os resultados indicaram que dilatações intermediárias (entre $r = 5$ e $r = 11$) alcançaram o melhor equilíbrio entre precisão e recall, fornecendo estimativas mais confiáveis da quantidade de plantas. Essa abordagem demonstrou viabilidade prática para o manejo florestal, apresentando-se como uma alternativa promissora para otimizar processos produtivos e contribuir para um modelo de reflorestamento mais eficiente e sustentável.

2 Objetivos geral e específico

Desenvolver e validar uma metodologia automatizada para contagem de plantas de eucalipto a partir de imagens de drones, utilizando modelos de segmentação semântica baseados em deep learning, com foco em precisão, escalabilidade e aplicabilidade no manejo florestal.

- Construir um dataset de imagens de eucalipto obtidas por drones, devidamente anotadas com a posição central de cada planta.
- Realizar o pré-processamento das imagens, incluindo divisão em blocos, ajustes de contraste, correção de cores, remoção de ruídos e normalização.
- Implementar e treinar modelos de segmentação semântica capazes de identificar plantas a partir das anotações dilatadas por diferentes raios (r).
- Avaliar o desempenho dos modelos por meio de métricas quantitativas (Precisão, recall, F1-score e α) e análises qualitativas dos resultados.
- Investigar o impacto da dilatação das anotações na redução de falsos positivos e falsos negativos.
- Validar a escalabilidade e a aplicabilidade prática da metodologia em diferentes cenários de plantio.

3 Trabalhos correlatos

A aplicação de técnicas de segmentação semântica baseadas em deep learning para o monitoramento de plantações florestais, especialmente de eucalipto, tem sido objeto de diversos estudos recentes, evidenciando a relevância e o potencial dessa abordagem para a agricultura de precisão e o manejo sustentável.

Um exemplo notável é o trabalho de [Costa, 2021], que investigou a detecção de florestas plantadas de eucalipto no Brasil utilizando imagens multiespectrais do

satélite Sentinel-2. O estudo comparou seis arquiteturas de redes neurais profundas, incluindo U-Net, DeepLabv3+, FPN, MANet, PSPNet e LinkNet, combinadas com diferentes codificadores como ResNet-101, ResNeXt-101 e EfficientNet-b3/b7. Os resultados indicaram que a combinação da arquitetura DeepLabv3+ com o codificador EfficientNet-b7 alcançou o melhor desempenho, com um IoU de 76,57%, demonstrando a eficácia dessa abordagem para a segmentação de áreas de plantio de eucalipto.

Outro estudo relevante é o de [Oliveira, 2022], que propôs uma arquitetura U-Net em dois estágios para a segmentação de áreas agrícolas utilizando imagens de satélite. O modelo foi ajustado por meio de técnicas de otimização de hiperparâmetros (Hyperopt e GridSearch), resultando em desempenho superior em termos de mIoU em comparação às outras arquiteturas empregadas em trabalhos similares.

Além disso, o trabalho de [Faria, 2023] explorou o uso de redes neurais convolucionais para a segmentação semântica de plantas daninhas em imagens aéreas de alta resolução obtidas por drones. O estudo avaliou o desempenho de nove modelos de deep learning na classificação de pixels em diferentes classes (planta, solo, espécie invasiva e fundo), destacando a aplicabilidade dessas técnicas para o manejo de culturas agrícolas.

Esses trabalhos nacionais dialogam diretamente com abordagens internacionais. No contexto de florestas plantadas, estudos recentes com UAV-LiDAR demonstraram que métodos de individual Tree Detection (ITD) em talhões de eucalipto alcançam alta acurácia, mas a custos elevados e maior complexidade de processamento tridimensional. Por outro lado, métodos com UAV-RGB e deep learning, como o DeepForest e o Detectree2, têm-se mostrado eficazes no delineamento de copas e na contagem de árvores em florestas tropicais e temperadas, evidenciando o potencial do sensoriamento remoto de baixo custo para tarefas florestais.

No contexto internacional, métodos recentes têm explorado arquiteturas de deep learning aplicadas à detecção e contagem individual de árvores. O DeepForest ([Weinstein et al., 2020]) apresenta uma abordagem baseada em redes convolucionais profundas (CNNs) para o delineamento de copas arbóreas a partir de imagens RGB de alta resolução, oferecendo uma solução acessível e adaptável a diferentes ecossistemas florestais.

De forma complementar, o Detectree2 ([Orland et al., 2023]) utiliza uma arquitetura U-Net aprimorada com múltiplas escalas e pós-processamento de componentes conectados para detecção e segmentação de copas em imagens aéreas provenientes de UAV-RGB e LiDAR, demonstrando desempenho robusto em ambientes tropicais e temperados.

Esses métodos reforçam a relevância do uso de modelos de segmentação semântica supervisionada para o mapeamento florestal, além de servirem como base

comparativa para o desenvolvimento da metodologia proposta neste trabalho.

No campo das arquiteturas de deep learning, a U-Net ([Ronneberger et al., 2015]) consolidou-se como referência em segmentação semântica, especialmente em cenários com rótulos limitados. A DeepLabv3+ ([Chen et al., 2018]) aprimorou a captura de contexto multiescala por meio do Atrous Spatial Pyramid Pooling, enquanto arquiteturas como FPN ([Li et al., 2018]) e YOLOv3 ([Redmon and Farhadi, 2018]) tornaram-se padrões em detecção multiescala e rápida, respectivamente. Já a Mask R-CNN ([He et al., 2017]) introduziu a segmentação por instância, permitindo a contagem e delineamento de indivíduos, sendo aplicada em contextos florestais e agrícolas.

Por fim, uma linha distinta, mas complementar, é a de mapas de densidade supervisionados por pontos (dot supervision). O trabalho seminal de [Lempitsky and Zisserman, 2010] inaugurou essa abordagem, que foi expandida por arquiteturas como MCNN ([Zhang et al., 2016]) e CSRNet ([Li et al., 2018]), obtendo grande sucesso em tarefas de contagem em multidões. Apesar da robustez para contagem global, esses métodos apresentam limitações em localização por indivíduo, o que reduz sua aplicabilidade direta em talhões de eucalipto, nos quais a contagem precisa por muda é essencial.

4 Materiais e métodos

A metodologia adotada neste trabalho foi estruturada em etapas sequenciais que vão desde a coleta e preparação dos dados até o treinamento e avaliação dos modelos de deep learning. O objetivo foi desenvolver um fluxo reprodutível e escalável para a contagem automatizada de plantas de eucalipto a partir de imagens aéreas de drones.

4.1 Coleta de dados

As imagens foram obtidas por meio de voos realizados com drones equipados com câmeras Red, Green, Blue (RGB) de alta resolução. Os voos foram planejados para garantir sobreposição lateral e frontal entre 70% e 80%, permitindo a geração de ortomosaicos consistentes. A altura média de voo foi definida de modo a assegurar um Ground Sampling Distance (GSD) adequado para distinguir mudas individuais.

As áreas selecionadas correspondem a talhões de eucalipto em fase inicial de crescimento, com espaçamento regular entre plantas. As condições de iluminação foram controladas, priorizando voos em horários de menor incidência de sombras.

O conjunto de dados utilizado neste trabalho foi composto por 4 ortomosaicos gerados a partir dos voos realizados, cobrindo diferentes talhões de eucalipto em

estágio inicial de crescimento. A partir desses ortomosaicos, foram extraídos 11.620 recortes (patches) de 256×256 pixels, distribuídos entre os conjuntos de treinamento (5.920 imagens), validação (2.400 imagens) e teste (3.300 imagens).

Essa divisão foi projetada para garantir a representatividade de diferentes condições de plantio, densidade e iluminação em cada partição do conjunto de dados. O tamanho dos recortes foi definido de forma a equilibrar o nível de detalhe das mudas com a limitação de memória da GPU, mantendo a proporção espacial adequada para a detecção individual das plantas nas imagens aéreas. Essa estratégia permitiu o treinamento eficiente dos modelos, preservando a variação visual necessária para uma generalização robusta durante o processo de inferência.

4.1.1 Anotação do conjunto de dados (dot supervision)

As mudas foram anotadas manualmente por meio de pontos centrais posicionados sobre o ápice visível de cada copa nas imagens RGB, seguindo protocolo único e revisão por amostragem. Esse esquema de rótulo (dot supervision) é amplamente utilizado quando se deseja priorizar custo e velocidade de anotação mantendo a localização individual dos alvos no nível de pixel [Lempitsky and Zisserman, 2010, Zhang et al., 2016, Li et al., 2018].

Como os modelos de segmentação supervisionada requerem máscaras binárias, cada ponto foi convertido em uma região circular por dilatação com raio r (em pixels). Formalmente, seja $\mathcal{P} = \{p_i\}$ o conjunto de pontos anotados; a máscara de treino M é definida como:

$$M = \bigcup_{p_i \in \mathcal{P}} \mathcal{B}(p_i, r),$$

onde $\mathcal{B}(p_i, r)$ é o disco de centro p_i e raio r . Foram avaliados $r \in \{1, 3, 5, 7, 11, 17, 21\}$, de modo a estudar o impacto do tamanho da região rotulada na relação precisão–recall do modelo.

Na avaliação, uma predição é considerada verdadeiro positivo se a distância euclidiana entre o centróide predito $\hat{p}$ e algum ponto de referência p_i satisfaz $d(\hat{p}, p_i) \leq \alpha$, onde α é o parâmetro de tolerância espacial. Valores de α maiores aceitam pequenas imprecisões de localização e tendem a elevar a recall, enquanto valores menores tornam o critério mais estrito e tendem a elevar a precisão. (Nesta pesquisa, analisamos α em uma faixa prática para o problema, reportada nos resultados.)

4.1.2 Vantagens e limitações.

A anotação por pontos é substancialmente mais barata e rápida que a vetorização por polígonos, permitindo rotular grandes áreas com consistência e foco na contagem

individual — requisito central deste trabalho. Em contrapartida, por não capturar o contorno exato da copa, a máscara derivada depende do parâmetro r ; por isso, investigamos sistematicamente vários raios e discutimos seus efeitos nas métricas. Essa escolha metodológica segue a literatura de dot supervision para contagem e segmentação densa [Lempitsky and Zisserman, 2010, Zhang et al., 2016, Li et al., 2018].

4.2 Pré-processamento

As imagens brutas passaram pelas seguintes etapas:

- Divisão em blocos (patches): recorte das imagens em dimensões fixas para adequação à memória da Unidade de Processamento Gráfico (GPU);
- Normalização: ajuste dos valores de intensidade dos pixels para a faixa $[0,1]$;
- Particionamento do conjunto: divisão estratificada em subconjuntos de treinamento, validação e teste, assegurando a representatividade de diferentes áreas de plantio em cada grupo.

A Figura 1 ilustra o processo de dilatação das anotações pontuais. Nela, cada ponto central representa uma muda identificada manualmente nas imagens RGB. À medida que o raio r aumenta, o ponto original é expandido para formar uma máscara circular maior, utilizada como rótulo durante o treinamento do modelo. Essa representação visual permite compreender como diferentes valores de r alteram o tamanho da região anotada e, consequentemente, a sensibilidade e a precisão do modelo de segmentação.

4.3 Ambiente computacional e configuração dos experimentos

Todos os experimentos foram realizados em ambiente Linux, utilizando o sistema operacional Ubuntu 20.04 LTS com suporte a GPU. As rotinas de treinamento e inferência foram implementadas em Python 3.10, empregando o framework PyTorch 2.1.0 em conjunto com a biblioteca MMSegmentation 1.2.0 [Contributors, 2020].

Os testes foram conduzidos em uma estação de trabalho equipada com uma GPU NVIDIA RTX 3090 (24 GB de VRAM), CPU AMD Ryzen 9 5950X (16 núcleos, 32 threads) e 128 GB de memória RAM. O ambiente foi gerenciado por meio de conda e as dependências principais incluíram mmcv, torchvision, opencv-python, numpy e matplotlib.

A configuração de hardware e software foi selecionada para garantir compatibilidade total com o MMSegmentation e permitir o treinamento eficiente dos modelos




Figura 1: Exemplo ilustrativo do processo de dilatação das anotações pontuais. À esquerda, as mudas são representadas por pontos centrais. À direita, observa-se a conversão desses pontos em regiões circulares (máscaras binárias) com diferentes raios de dilatação ($r = 3, 11, 21$), utilizadas como rótulos para o treinamento dos modelos.

de segmentação semântica avaliados (U-Net, DeepLabv3+ e FPN). O código-fonte e os experimentos foram organizados em diretórios estruturados por tipo de dilatação (r) e versão de modelo, assegurando reprodutibilidade e rastreabilidade dos resultados.

4.4 Treinamento dos modelos

Para a etapa de treinamento, foi utilizado o framework MMSegmentation [Contributors, 2020], que oferece implementações otimizadas de arquiteturas modernas de segmentação semântica. Esse ambiente fornece suporte direto a modelos clássicos e recentes de deep learning voltados à segmentação densa, incluindo a Fully Convolutional Network (FCN) [Long et al., 2015], que estabeleceu a base conceitual para o uso de convoluções totalmente conectadas em tarefas de segmentação semântica.

Entre as arquiteturas avaliadas, destacam-se as redes U-Net, DeepLabv3+ e Feature Pyramid Network (FPN). A FPN foi incluída por sua capacidade de integrar informações em múltiplas escalas por meio de uma pirâmide hierárquica de recursos, o que melhora a detecção de objetos de diferentes tamanhos e contribui para uma segmentação mais detalhada das mudas de eucalipto. Essa diversidade de modelos permitiu uma análise comparativa do desempenho entre abordagens baseadas em extração de contexto global (DeepLabv3+), reconstrução simétrica (U-Net) e fusão multiescala (FPN), enriquecendo a avaliação da metodologia proposta.

O treinamento foi conduzido com 20 000 iterações, tamanho de lote (batch size) de 32 e validações a cada 2 000 iterações. O otimizador utilizado foi o Stochastic Gradient Descent (SGD) com taxa de aprendizado inicial de 0,01, momento de 0,9 e decaimento de peso de 0,0005, seguindo uma política de decaimento polinomial (PolyLR) até 0,0001. O monitoramento das métricas nos conjuntos de treinamento e validação, aliado ao ajuste fino (fine-tuning) dos hiperparâmetros, buscou evitar o sobreajuste (overfitting) e garantir a convergência estável dos modelos. O conjunto de validação foi reservado exclusivamente para a avaliação final e comparação de desempenho entre as arquiteturas.

4.5 Pós-processamento e contagem

Após a geração da máscara predita pelo modelo, aplicou-se um processo de detecção de componentes conectados para identificar regiões correspondentes a plantas individuais. O centróide de cada componente foi extraído e contabilizado, originando a estimativa do número de mudas por imagem.

Na avaliação, utilizou-se um parâmetro de tolerância espacial α , definido como a distância máxima (em pixels) entre um centróide previsto e um ponto de referência para que o acerto fosse considerado verdadeiro positivo. Valores de α entre




Figura 2: Relação entre os valores de alpha e a Precisão para diferentes dilatações.

10 e 70 pixels foram analisados comparativamente, permitindo observar o efeito dessa tolerância sobre as métricas de precisão e recall.

5 Experimentos e resultados

Nesta seção, apresentamos e discutimos os resultados obtidos a partir da aplicação do método proposto. A avaliação foi dividida em duas frentes: quantitativa, com métricas objetivas de desempenho, e qualitativa, com análise visual de casos específicos. O objetivo é compreender não apenas o desempenho numérico do modelo, mas também seu comportamento em situações desafiadoras e seu impacto na tarefa de estimativa de produtividade agrícola.

5.1 Resultados Quantitativos

Os resultados quantitativos são apresentados por meio das métricas clássicas de avaliação: Precisão (Precision), recall (Recall) e F1-Score. Essas métricas foram calculadas para diferentes níveis de dilatação aplicados às máscaras de dilatações $r = 1, 3, 5, 7, 11, 17$ e 21 e estão detalhadas nos Gráficos 2, 3 e 4, bem como na Tabela 1.

Como esperado, a análise dos gráficos revela uma tendência clara: à medida que o parâmetro α aumenta, observa-se uma elevação consistente no recall, enquanto o impacto sobre a precisão e o F1-score é mais sutil. O parâmetro α representa o




Figura 3: Relação entre os valores de alpha e a recall.




Figura 4: Relação entre os valores de alpha e o F1-Score.

Tabela 1: Métricas de Precisão (P), recall (R) e F1 em diferentes valores de dilatação (r), organizadas por $\alpha = 10$ e $\alpha = 70$.

Dilatação (r)	$\alpha = 10$			$\alpha = 70$		
	P	R	F1	P	R	F1
1	0.33	0.37	0.35	0.73	0.82	0.77
3	0.32	0.37	0.34	0.71	0.80	0.75
5	0.36	0.44	0.40	0.72	0.88	0.79
7	0.33	0.38	0.35	0.71	0.82	0.76
11	0.34	0.45	0.38	0.67	0.91	0.77
17	0.31	0.41	0.35	0.64	0.86	0.73
21	0.29	0.43	0.34	0.62	0.92	0.74

raio de dilatação aplicado às anotações pontuais, funcionando como um fator de tolerância espacial. Em outras palavras, quanto maior o α , maior a região considerada como "planta" ao redor do ponto anotado, o que aumenta a probabilidade de que uma previsão do modelo seja contabilizada como acerto.

Esse comportamento explica a melhora no recall: regiões dilatadas reduzem os falsos negativos, já que pequenas imprecisões na localização das previsões passam a ser aceitas. Em contrapartida, a dilatação também pode introduzir falsos positivos, quando áreas sem plantas reais passam a ser classificadas como corretas, o que tende a reduzir a precisão. Assim, os resultados confirmam a importância de definir níveis intermediários de dilatação, nos quais se alcança melhor equilíbrio entre precisão e recall, refletindo-se em valores mais robustos de F1-score.

- Precisão - mede quantas das plantas detectadas pelo sistema são realmente verdadeiras. Valores mais altos indicam menos "contagens a mais". Em contextos como esse, uma alta precisão significa menor risco de superestimar o número de plantas.
- Recall (recall) - mede a capacidade do sistema de identificar todas as plantas presentes. Um baixo recall implica que o sistema está "deixando de contar plantas que existem", o que pode subestimar a produtividade real.
- F1-Score - pondera os dois aspectos anteriores e representa um equilíbrio entre precisão e recall. É especialmente útil quando precisamos considerar tanto os falsos positivos quanto os falsos negativos.

A decisão sobre qual dilatação adotar depende diretamente do contexto do produtor. Se o objetivo for uma estimativa conservadora (evitar contar plantas que não existem), valores mais baixos de dilatação (como $\text{root}3$ ou $\text{root}5$) com maior precisão podem ser mais adequados. Por outro lado, se a prioridade for não deixar

de contar nenhuma planta verdadeira, dilatações maiores (como root11 ou root17) com maior recall são preferíveis.

Em termos de F1-score que pondera ambos os erros os melhores desempenhos foram observados em root5 a root11, sugerindo um bom equilíbrio nesses níveis.

5.2 Resultados Qualitativos

Para além das métricas, é fundamental entender como o modelo se comporta visualmente, especialmente em casos complexos. As Figuras 5, 6, 7 e 8 apresentam exemplos de imagens em que o modelo acertou e cometeu erros por omissão.



Figura 5: Exemplo 1: Planta existente marcada.




Figura 6: Exemplo 1: Planta existente marcada.



Figura 7: Exemplo 2: Planta não existente não marcada.



Figura 8: Exemplo 2: Planta não existente não marcada.



Figura 9: Exemplo 3: Planta existente não marcada.




Figura 10: Exemplo 3: Planta existente não marcada.




Figura 11: Exemplo 4: Planta existente marcada.



Figura 12: Exemplo 4: Planta existente marcada.

Estas imagens reforçam os dados quantitativos e ajudam a compreender como a dilatação impacta visualmente a segmentação. Em casos de alta densidade de raízes, uma dilatação maior pode ajudar a garantir que as conexões sejam mantidas, evitando subcontagem. Já em ambientes com muitos resíduos ou artefatos, dilatações maiores podem causar superestimação, marcando áreas indevidas como raízes.

5.3 Impacto Prático no Campo

O objetivo final do sistema é auxiliar na contagem de plantas para estimar a produtividade agrícola. Assim, erros por omissão podem resultar em subestimativas da produção, enquanto erros por excesso podem superestimar o potencial da lavoura.

O problema que buscamos resolver está diretamente ligado à estimativa da produtividade agrícola a partir da contagem de plantas. Portanto, a acurácia do modelo não é um fim em si, mas um meio para tomada de decisão no campo. Um modelo que sistematicamente subestima a quantidade de plantas pode levar a decisões erradas sobre o potencial produtivo da lavoura, enquanto um que superestima pode causar expectativa irreal.

A análise combinada entre resultados quantitativos e qualitativos permite afirmar que o modelo com dilatação entre root5 e root11 oferece o melhor compromisso entre erro de omissão e de inclusão, proporcionando maior confiabilidade para o produtor.

6 Conclusão

O presente trabalho apresentou uma metodologia inovadora para a contagem automatizada de mudas de eucalipto utilizando imagens aéreas obtidas por drones e modelos de segmentação semântica baseados em deep learning. A proposta buscou enfrentar um desafio recorrente no setor florestal: a necessidade de estimativas rápidas, precisas e economicamente viáveis da produtividade de plantações.

Os experimentos realizados demonstraram que o uso de dilatações intermediárias nas anotações (entre $r = 5$ e $r = 11$) proporcionou o melhor equilíbrio entre precisão e recall, refletido em valores mais robustos de F1-score. Essa configuração permitiu reduzir tanto os erros de omissão quanto os de inclusão, resultando em contagens mais confiáveis e, consequentemente, em estimativas de produtividade mais próximas da realidade do campo.

Além das contribuições técnicas, o estudo reforça o papel da inteligência artificial como ferramenta estratégica para modernização e sustentabilidade do setor florestal. A automatização da contagem de mudas representa não apenas ganhos operacionais em termos de tempo e custo, mas também maior embasamento para tomadas de decisão no manejo de reflorestamentos.

Como perspectivas futuras, destaca-se a possibilidade de ampliar a metodologia para diferentes estágios de crescimento das plantas, integrar informações multiespectrais e explorar arquiteturas mais recentes de deep learning que incorporem aprendizado auto-supervisionado. Também se recomenda avaliar o impacto de diferentes estratégias de pré-processamento e normalização de imagens, incluindo abordagens como a normalização z-score e a normalização por canal (mean-std), que podem contribuir para uma melhor estabilidade do treinamento e maior capacidade de generalização dos modelos. Além disso, sugere-se a aplicação prática em larga escala por empresas do setor, consolidando a metodologia como uma ferramenta efetiva no contexto da silvicultura de precisão.

Em síntese, este trabalho comprova a viabilidade do uso de técnicas de visão computacional e aprendizado profundo para o monitoramento automatizado de plantações de eucalipto, constituindo-se em um avanço relevante tanto do ponto de vista acadêmico quanto prático. Assim, este trabalho evidencia o potencial da engenharia de computação em oferecer soluções inovadoras e aplicáveis, contribuindo de forma concreta para a evolução do setor florestal e para a construção de um modelo produtivo mais eficiente e sustentável.

Referências

- [Chen et al., 2018] Chen, L.-C., Zhu, Y., Papandreou, G., Schroff, F., and Adam, H. (2018). Encoder-decoder with atrous separable convolution for semantic image segmentation. In Proceedings of the European Conference on Computer Vision (ECCV), pages 801–818.
- [Contributors, 2020] Contributors, O. (2020). Mmsegmentation: Openmmlab semantic segmentation toolbox and benchmark. <https://github.com/open-mmlab/msegmentation>. Acesso em: 3 nov. 2025.
- [Costa, 2021] Costa, J. P. (2021). Detecção de florestas plantadas de eucalipto no brasil utilizando deep learning e imagens sentinel-2. Dissertação de mestrado, Universidade Federal de Minas Gerais, Belo Horizonte.
- [FAO, 2020] FAO (2020). Global forest resources assessment 2020: Brazil report. Série histórica de área plantada por espécie (20132017). Acesso em: 2025-11-03.
- [Faria, 2023] Faria, L. (2023). Segmentação semântica de plantas daninhas em imagens aéreas de alta resolução com deep learning. Tese de doutorado, Universidade Federal de Viçosa, Viçosa.
- [He et al., 2017] He, K., Gkioxari, G., Dollár, P., and Girshick, R. (2017). Mask r-cnn. In Proceedings of the IEEE International Conference on Computer Vision (ICCV), pages 2961–2969.
- [IBGE and Agência IBGE Notícias, 2025] IBGE and Agência IBGE Notícias (2025). Valor de produção da silvicultura e da extração vegetal cresce 16,7% e soma r\$ 44,3 bilhões. Dados citam área total plantada ~9,9 milhões ha (2023) e participação do eucalipto ~77,6%. Acesso em: 2025-11-03.
- [Indústria Brasileira de Árvores (Ibá), 2023] Indústria Brasileira de Árvores (Ibá) (2023). Relatório anual 2023. Acesso em: 2025-11-03.

- [Lempitsky and Zisserman, 2010] Lempitsky, V. and Zisserman, A. (2010). Learning to count objects in images. In *Advances in Neural Information Processing Systems (NeurIPS)*, pages 1324–1332.
- [Li et al., 2018] Li, Y., Zhang, X., and Chen, D. (2018). Csrnet: Dilated convolutional neural networks for understanding the highly congested scenes. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 1091–1100.
- [Long et al., 2015] Long, J., Shelhamer, E., and Darrell, T. (2015). Fully convolutional networks for semantic segmentation. In *2015 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 3431–3440, Los Alamitos, CA, USA. IEEE Computer Society.
- [Oliveira, 2022] Oliveira, M. (2022). Segmentação de áreas agrícolas com u-net em dois estágios e otimização de hiperparâmetros. Dissertação de mestrado, Universidade de São Paulo, São Paulo.
- [Orland et al., 2023] Orland, I., Slesak, R. A., Smith, J., Macfarlane, D. W., and Latimer, A. M. (2023). Detectree2: Deep learning for tree crown detection and segmentation from aerial imagery. *Remote Sensing*, 15(3):547.
- [Redmon and Farhadi, 2018] Redmon, J. and Farhadi, A. (2018). Yolov3: An incremental improvement. In *arXiv preprint arXiv:1804.02767*.
- [Ronneberger et al., 2015] Ronneberger, O., Fischer, P., and Brox, T. (2015). U-net: Convolutional networks for biomedical image segmentation. In *Proceedings of the Medical Image Computing and Computer-Assisted Intervention (MICCAI)*, pages 234–241. Springer.
- [Weinstein et al., 2020] Weinstein, B. G., Marconi, S., Bohlman, S. A., Zare, A., and White, E. P. (2020). Deepforest: A python package for rgb deep learning tree crown delineation. *Methods in Ecology and Evolution*, 11(12):1743–1751.
- [Zhang et al., 2016] Zhang, Y., Zhou, D., Chen, S., Gao, S., and Ma, Y. (2016). Single-image crowd counting via multi-column convolutional neural network. In *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition (CVPR)*, pages 589–597.