



## IDENTIFICAÇÃO DE ÁREAS RURAIS UTILIZANDO TÉCNICAS DE VISÃO COMPUTACIONAL EM IMAGENS DE SATÉLITE

Caroline F. de MELO<sup>1</sup>; Douglas D. de C. BRAZ<sup>2</sup>

### RESUMO

Este trabalho trata de uma pesquisa em andamento que tem o objetivo de desenvolver um modelo de Visão Computacional baseado na arquitetura YOLOv8 para a detecção automática de elementos em imagens de satélite de áreas rurais, como lavouras, edificações, pastagens, vegetação e solo exposto, facilitando o mapeamento territorial agrícola. Utilizando um conjunto de dados preparado manualmente para a tarefa, o modelo inicialmente foi treinado, validado e testado com o auxílio de técnicas de aumento de dados. Os resultados iniciais mostraram desempenho satisfatório para classes bem definidas, como edificações, mas menor precisão e revocação para categorias visualmente semelhantes, como pastagens e solo exposto. Conclui-se que ajustes no balanceamento dos dados e nos parâmetros do modelo são necessários nos próximos passos da pesquisa para melhorar sua eficácia no monitoramento agrícola automatizado.

### Palavras-chave:

Aprendizado de Máquina; Detecção de Objetos; Monitoramento Agrícola.

### 1. INTRODUÇÃO

A evolução da Inteligência Artificial tem ampliado as possibilidades em diversos segmentos de pesquisa, destacando-se o Aprendizado de Máquina e a Visão Computacional como técnicas promissoras para a resolução de problemas complexos em diferentes áreas, incluindo a agricultura (Patrício; Rieder, 2018).

Nesse contexto, a implementação de sistemas automatizados no setor agrícola representa um avanço em relação aos métodos manuais tradicionais, ao buscar soluções que demonstrem mais precisão e exatidão nas tarefas, além de reduzir a dependência da interferência humana (Ghazal; Munir; Qureshi, 2024). O uso dessas tecnologias permite a análise de grandes volumes de imagens, favorecendo a rapidez no processo de pesquisa do ambiente rural.

O presente trabalho tem como objetivo principal o desenvolvimento de modelos baseados em inteligência artificial utilizando técnicas de visão computacional para a identificação de estruturas relevantes em imagens de satélite de áreas rurais. A proposta busca automatizar a detecção de elementos característicos do ambiente rural, como lavouras, propriedades, pastagens, vegetação e solo exposto, contribuindo, assim, para o mapeamento territorial e o monitoramento agrícola.

### 2. FUNDAMENTAÇÃO TEÓRICA

<sup>1</sup>Bolsista de Iniciação Científica, IFSULDEMINAS - campus Poços de Caldas. E-mail: caroline.melo@alunos.ifsuldeminas.edu.br

<sup>2</sup>Orientador, IFSULDEMINAS - campus Poços de Caldas. E-mail: douglas.braz@ifsuldeminas.edu.br

O avanço tecnológico tem impulsionado transformações significativas no setor agrícola por meio de técnicas de Inteligência Artificial, como as contidas na área da Visão Computacional. Essa tecnologia visa replicar a visão humana computacionalmente, utilizando imagens digitais para interpretar e compreender cenas, fornecendo informações precisas sobre o ambiente a partir de diversas tarefas, entre elas a detecção de objetos, que permite a localização de áreas de interesse em uma imagem (Lu; Young, 2020).

No campo da Visão Computacional, a abordagem mais utilizada para tarefas de detecção de objetos é com o uso de redes neurais convolucionais. Essas redes se destacam por terem desempenho superior se comparadas a outras redes neurais, lidando melhor com dados de imagens (IBM, 2025). Dessa forma, arquiteturas baseadas em redes neurais convolucionais se tornam uma técnica adequada para resolução de problemas no setor agrícola, que demanda soluções mais robustas e específicas. Ao integrar essas tecnologias com o monitoramento agrícola, é possível extrair informações relevantes e detalhadas sobre áreas ambientais, como a localização e identificação de lavouras, pastagens, edificações, solo exposto e vegetação.

Considerando os conceitos abordados neste tópico, a próxima seção trará detalhes da metodologia aplicada nesta pesquisa.

### **3. MATERIAL E MÉTODOS**

Este trabalho caracteriza-se como uma pesquisa aplicada e experimental, uma vez que busca resolver um problema prático do monitoramento agrícola por meio da construção de um dataset e um modelo de Visão Computacional. A metodologia adotada se divide em cinco etapas principais:

1. Coleta de imagens de satélite utilizando o serviço Google Maps<sup>3</sup> com foco em áreas rurais e escolhidas com base em critérios de visibilidade e diversidade de elementos de interesse;
2. Rotulagem manual com caixas delimitadoras para anotação dos objetos de interesse presentes nas imagens utilizando a ferramenta de código aberto LabelImg<sup>4</sup>;
3. Construção do conjunto de dados contendo as imagens e seus arquivos de anotação no formato compatível com a ferramenta utilizada para desenvolvimento do modelo e divisão dos dados em subconjuntos de treinamento, validação e teste;
4. Desenvolvimento de um modelo de detecção de objetos utilizando a arquitetura YOLO<sup>5</sup> para realizar treinamento, validação e teste com os dados rotulados e os parâmetros ajustados;
5. Refinamento do modelo desenvolvido a partir de ajustes nos parâmetros com base na

---

<sup>3</sup> Mais informações em: <https://maps.google.com/>

<sup>4</sup> Repositório disponível em: <https://github.com/HumanSignal/labelImg>

<sup>5</sup> Documentação disponível em: <https://docs.ultralytics.com/pt/>

avaliação dos resultados obtidos.

Inicialmente, foi feito o uso da ferramenta para aumento de dados Albumentations<sup>6</sup>, que permite alterações nas características da imagem como a cor, tamanho, rotação e luminosidade, de forma a aumentar a quantidade de dados no conjunto de forma rápida e com menos trabalho manual.

As métricas para avaliação do modelo utilizadas até o presente momento da pesquisa foram a precisão, que mede a proporção de detecções feitas corretamente; a revocação, que mede a completude das detecções; e a mAP que faz uma média da precisão para todas as classes.

#### 4. RESULTADOS E DISCUSSÃO

O modelo de detecção de objetos sendo utilizado neste trabalho é o YOLOv8s, com um conjunto de 700 imagens manualmente rotuladas e posteriormente aumentadas para cerca de 2000. Na primeira fase de implementação, estão sendo utilizados 70% dos dados para o treinamento, 15% para a validação e 15% para o teste. Na figura 1, após a fase de teste feita depois do treinamento e validação, foi possível observar a quantidade de instâncias em cada uma das classes e as respectivas métricas: precisão, revocação e mAP.

Figura 1 - Imagem extraída do teste do modelo via terminal de execução

Class	Images	Instances	Box(P	R	mAP50	mAP50-95) :
all	290	3531	0.728	0.522	0.631	0.408
agricultural crops	230	634	0.667	0.495	0.59	0.377
buildings	190	643	0.779	0.684	0.774	0.533
exposed soil	205	488	0.654	0.481	0.549	0.337
pasture	100	150	0.798	0.413	0.584	0.355
vegetation	283	1616	0.739	0.537	0.657	0.439

Fonte: elaborada pelos autores.

É possível observar que o modelo apresenta desempenho variável entre as classes. *Buildings* é a categoria com melhores resultados, indicando boa capacidade de identificação dessa classe. Em contraste, *exposed soil* tem o pior desempenho, com baixa precisão e revocação, possivelmente devido à semelhança visual com outras classes. A classe *vegetation*, apesar de ser a mais frequente, tem revocação relativamente baixa, sugerindo que muitas instâncias não foram detectadas. O desempenho médio geral indica que o modelo precisa de melhorias, especialmente em classes menos distintas visualmente. Essa variação é consistente com estudos anteriores, como o de Tahir *et al* (2022), que traz destaque para o YOLO em relação a velocidade, mas indica a necessidade de ajustes e otimizações da arquitetura para aumentar o desempenho.

Tendo em mente essas informações, os próximos passos estão relacionados à adoção de

<sup>6</sup> Documentação disponível em: <https://albumentations.ai/docs/>

técnicas para melhorar esses resultados, como balanceamento de dados e refinamento dos parâmetros, sendo essas alternativas que podem ajudar a aumentar a performance geral do modelo.

## 5. CONCLUSÃO

O trabalho demonstra a viabilidade do uso de Visão Computacional na detecção de elementos em imagens de satélite de áreas rurais, utilizando a arquitetura YOLOv8. Apesar de bons resultados, especialmente na identificação de edificações, o modelo apresenta desempenho inferior em classes menos distintas, como pastagem e solo exposto. Uma limitação importante do estudo foi o uso de um conjunto de dados relativamente pequeno e com classes desbalanceadas, o que restringe a generalização do modelo para diferentes regiões e condições. Esses resultados indicam a necessidade de melhorias nos próximos passos, como balanceamento do conjunto de dados e ajustes nos parâmetros, a fim de aumentar a precisão e a aplicação do modelo em contextos reais de monitoramento agrícola.

## REFERÊNCIAS

ALBUMENTATIONS. **Documentação Albumentations**. Disponível em: <https://albumentations.ai/docs/>. Acesso em: 30 jul. 2025.

GHAZAL, Sumaira; MUNIR, Arslan; QURESHI, Waqar S. Computer vision in smart agriculture and precision farming: Techniques and applications. **Artificial Intelligence in Agriculture**, v. 13, p. 64-83, 2024.

GOOGLE. **Google Maps**. Disponível em: <https://maps.google.com/>. Acesso em: 30 jul. 2025.

HUMANSIGNAL. **labellmg: GitHub repository**. Disponível em: <https://github.com/HumanSignal/labellmg>. Acesso em: 30 jul. 2025.

IBM. **O que são redes neurais convolucionais?** Disponível em: <https://www.ibm.com/br-pt/think/topics/convolutional-neural-networks>. Acesso em: 30 jul. 2025.

LU, Yuzhen; YOUNG, Sierra. A survey of public datasets for computer vision tasks in precision agriculture. **Computers and Electronics in Agriculture**, v. 178, p. 105760, 2020.

PATRÍCIO, Diego Inácio; RIEDER, Rafael. Computer vision and artificial intelligence in precision agriculture for grain crops: A systematic review. **Computers and electronics in agriculture**, v. 153, p. 69-81, 2018.

TAHIR, Arsalan et al. Automatic target detection from satellite imagery using machine learning. **Sensors**, v. 22, n. 3, p. 1147, 2022.

ULTRALYTICS. **Documentação oficial Ultralytics**. Disponível em: <https://docs.ultralytics.com/pt/>. Acesso em: 30 jul. 2025.