

# **Visão Computacional Aplicada à Identificação e Segmentação de Animais: Uma Revisão da Literatura**

**Leonardo J. Antunes<sup>1,2</sup>, Matheus Santos<sup>1,2</sup>, Henrique S. Cunha<sup>1,2</sup>, Juliana S. Silva<sup>1</sup>**

<sup>1</sup>Departamento de Computação – Campus Cuiabá – Cel. Octayde Jorge da Silva – Instituto Federal de Mato Grosso (IFMT) – 78005-390 – Cuiabá – MT – Brasil

<sup>2</sup>IFMT Maker FabLab, Campus Cuiabá – Cel. Octayde Jorge da Silva – IFMT – Cuiabá – MT – Brasil

{leonardo.antunes, henrique.cunha, matheus.santos}@estudante.ifmt.edu.br,  
juliana.silva@ifmt.edu.br

**Abstract.** Computer Vision has become fundamental to Precision Livestock Farming by automating non-invasive tasks, such as animal counting and weight estimation. In this context, this article presents a literature review on Computer Vision applied to animal identification and segmentation. Following a research protocol, 15 articles published between 2020 and 2025 were analyzed. The results indicate a predominance of customized models to overcome practical challenges, such as animal occlusion and hardware constraints. One contribution of this study is the identification of gaps in the literature regarding YOLO-based studies on animal detection and segmentation.

**Resumo.** A Visão Computacional tem se tornado fundamental para a Pecuária de Precisão ao automatizar tarefas, como a contagem e a estimativa de peso de animais, de forma não invasiva. Diante desse contexto, este artigo apresenta uma revisão da literatura sobre Visão Computacional aplicada à identificação e segmentação de animais. A partir de um protocolo de pesquisa, foram analisados 15 artigos, publicados entre 2020 e 2025. Os resultados apontam para a predominância de modelos customizados para superar desafios práticos, como oclusão de animais e limitações de hardware. Uma contribuição deste trabalho é a identificação de lacunas na literatura acerca de estudos de detecção e segmentação de animais, baseados em YOLO.

## **1. Introdução**

A Agropecuária é um dos pilares da economia no Brasil, sendo responsável pela produção de alimentos e de animais não apenas para o mercado interno, mas também para diversos outros países. Na Agricultura tem se destacado com a produção de soja, algodão e milho, enquanto na Pecuária, na produção de carne bovina, suína e de aves. Dessa forma, a Agropecuária representa 23,5% do Produto Interno Bruto (PIB) do país, no ano de 2024. (CEPEA, 2025)

A Pecuária tem sido impulsionada, nos últimos anos, pelas novas tecnologias com a finalidade de contribuir para a melhoria da produção animal e a mitigação da insegurança alimentar global – emergindo, assim, um novo campo de estudo denominado Pecuária de Precisão (Berckmans, 2017).

Essa abordagem tecnológica vem transformando o cotidiano do produtor rural, pois disponibiliza um conjunto de ferramentas que trazem inovações, como sensores, Sistema de Posicionamento Global (GPS - *Global Positioning System*), drones, câmeras de monitoramento, entre outros recursos tecnológicos, que aplicam conceitos como Aprendizado de Máquina (*Machine Learning*), Metadados (*Big Data*) e Visão Computacional. Isso pode ser confirmado no trabalho de Bernardi *et al.* (2022), quando mencionam que o desenvolvimento de soluções tecnológicas, baseadas na aplicação de sistemas inteligentes e automatizados às pastagens, pode contribuir para o processo de tomada de decisão nos sistemas de produção.

De forma complementar, Silva *et al.* (2023) descrevem que a implementação de tecnologias avançadas, como Inteligência Artificial (IA), tem se tornado cada vez mais presente e relevante no agronegócio, mostrando-se um mercado promissor. No entanto, a Agricultura ainda atrai um volume maior de investimentos e inovações tecnológicas, quando comparada com a Pecuária.

Dentre as diversas aplicações da IA, nesse contexto, destaca-se o uso do Aprendizado Profundo (*Deep Learning*) na área de Visão Computacional – um campo da IA, que dispõe de ferramentas que possibilitam a um computador “enxergar como um humano”, a partir de um conjunto de imagens e/ou vídeos. Essa aplicação traz benefícios relevantes para o ambiente rural como, a possibilidade de identificar e monitorar diversos animais, de forma simultânea e não invasiva (Menezes *et al.*, 2024). Esse monitoramento é essencial para garantir o bem-estar e a eficiência da produtividade de vacas leiteiras (Antognoli *et al.*, 2025).

Assim sendo, o objetivo desse artigo é apresentar uma revisão da literatura sobre Visão Computacional aplicada à identificação e segmentação de animais. Pretende-se, a partir dessa análise, demonstrar áreas pouco exploradas neste domínio e avaliar a viabilidade do uso de Visão Computacional na Pecuária de Precisão.

Dessa forma, o trabalho está estruturado em 5 seções, incluindo esta introdução. A seção 2 apresenta o referencial teórico desta pesquisa e, a seção 3, a metodologia utilizada. Logo após, a seção 4 traz os resultados e discussões sobre as abordagens de detecção e segmentação de animais. Por fim, a seção 5 aborda as considerações finais.

## 2. Referencial Teórico

Essa seção tem o objetivo de apresentar os conceitos técnicos essenciais para a compreensão da revisão da literatura realizada, como Aprendizado de Máquina, Aprendizado Profundo, Classificação de Imagens, Detecção e Segmentação de Objetos.

### 2.1. Aprendizado de Máquina e Aprendizado Profundo

O Aprendizado de Máquina (*Machine Learning*), campo basilar da área de IA, permite que sistemas desenvolvam capacidade de aprender com dados, enquanto seu subcampo, o Aprendizado Profundo (*Deep Learning*), utiliza Redes Neurais Profundas para extrair características hierárquicas, automaticamente, de dados brutos, como *pixels* de imagem (Goodfellow, 2016).

Dentro desse contexto, destacam-se as Redes Neurais Convolucionais (*Convolutional Neural Networks* – CNNs), as quais emergem como uma arquitetura especializada no processamento de imagens. Projetadas para trabalhar com dados em estrutura de *grid*, como imagens digitais, são baseadas na operação de convolução, na qual filtros deslizantes (*kernels*) detectam características visuais hierárquicas, desde bordas

simples até formas complexas (LeCun *et al.*, 2015). Essa arquitetura tornou-se fundamental para a Visão Computacional moderna após demonstrar avanços significativos em tarefas de classificação (Krizhevsky *et al.*, 2012). Como exemplo, pode-se mencionar a identificação de espécies, raças ou doenças em animais, a partir de fotografias, onde a CNN aprende a reconhecer padrões visuais característicos.

Para aplicações de Visão Computacional no domínio da Pecuária de Precisão, emerge um desafio frequente: a escassez de grandes bancos de imagens. Nesse sentido, a Transferência de Aprendizado (*Transfer Learning*) surge como uma técnica fundamental para contornar esta limitação (Pan e Yang, 2010). A abordagem consiste em aproveitar o conhecimento de uma CNN pré-treinada em um banco de imagens massivo e genérico, e refiná-la (*fine-tuning*) com um número reduzido de imagens do domínio específico, como fotografias de gado ou suíños.

Dessa forma, a técnica permite desenvolver modelos robustos e de alta precisão, sem a necessidade de criar extensos bancos de imagens, a partir do zero, viabilizando e acelerando o desenvolvimento de soluções práticas de Visão Computacional para a Pecuária de Precisão. Estas arquiteturas e técnicas fornecem a base para a execução das tarefas fundamentais em Visão Computacional, as quais são detalhadas a seguir.

## 2.2. Classificação de Imagens

Classificação de imagens é uma tarefa fundamental da Visão Computacional que consiste em atribuir uma categoria a uma imagem inteira. Na Pecuária de Precisão, esta técnica é amplamente utilizada para automatizar diagnósticos e avaliações, como a classificação do escore de condição corporal de bovinos, a identificação de comportamentos (por exemplo, ruminando, em pé ou deitado) ou a detecção de estados de saúde, a partir de fotografias dos animais.

O avanço no desempenho dessa tarefa deve-se, em grande parte, ao desenvolvimento de arquiteturas profundas especializadas. Um marco importante foi a introdução da Rede Neural Residual (ResNet), por He *et al.* (2016). Esta arquitetura resolveu um problema crucial: o desaparecimento do gradiente (*vanishing gradient*) em redes muito profundas, por meio de suas conexões residuais. Como resultado, tornou-se viável treinar redes com dezenas ou centenas de camadas, obtendo ganhos notáveis de precisão, sem um aumento computacional inviável.

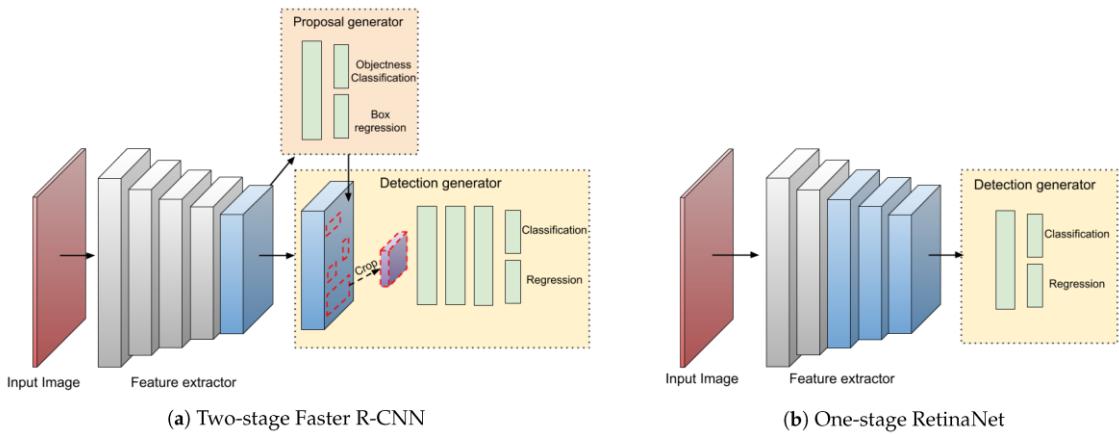
Buscando otimizar ainda mais esse equilíbrio, a EfficientNet (Tan e Le, 2019) introduziu um método de escalonamento composto, que ajusta, de forma coordenada, a profundidade, a largura e a resolução da rede. Contudo, a classificação de imagens se limita a cenários que exigem um único rótulo, o que motivou o desenvolvimento de abordagens mais granulares como a detecção de objetos – a qual é descrita na próxima subseção.

## 2.3 Detecção de Objetos

Detecção de objetos é uma tarefa fundamental de Visão Computacional que tem como objetivo encontrar e identificar diversos itens em uma imagem. Na Pecuária de Precisão, essa técnica é essencial para automatizar processos como a contagem de animais em um curral, a localização de indivíduos em um rebanho ou a identificação de partes corporais específicas, como a cabeça ou o úbere, para análises mais detalhadas.

Para a tarefa de detecção de objetos, os algoritmos podem ser classificados em duas categorias (Figura 1), conforme sua abordagem para balancear velocidade e precisão: (i) detectores de um estágio; e (ii) detectores de dois estágios. Os detectores de um estágio (*One-Stage*), como o YOLO (*You Only Look Once*), proposto por Redmon *et al.* (2016), e o

SSD (*Single Shot MultiBox Detector*), de Liu *et al.* (2016), tratam a detecção como um problema de regressão, prevendo as caixas delimitadoras e as classes diretamente em uma única passagem pela rede. Já os detectores de dois estágios (*Two-Stage*), como a família *Faster R-CNN* (Ren *et al.*, 2016), primeiro geram propostas de região de interesse e, depois, classificam e refinam essas regiões.



**Figura 1. Abordagens One-Stage e Two-Stage (Carranza-Garcia, 2021)**

A tarefa de detecção cria uma caixa delimitadora ao redor do objeto, o que se mostra insuficiente para análises de contornos exatos, onde se faz necessária uma maior precisão – que é encontrada na segmentação de objetos, como descrito a seguir.

## 2.4. Segmentação de Objetos

Segmentação de objetos é uma tarefa fundamental de Visão Computacional que vai além da simples detecção, realizando uma análise, *pixel a pixel*, para delimitar com precisão os contornos dos objetos. Na Pecuária de Precisão essa técnica é importante para análises morfológicas detalhadas, como a estimativa automática de peso vivo, monitoramento de crescimento e identificação de regiões anatômicas específicas, para avaliação de saúde.

Para a tarefa de segmentação de objetos, os algoritmos podem ser classificados em duas categorias, conforme sua abordagem: (i) segmentação semântica; e (ii) segmentação de instâncias. A segmentação semântica classifica todos os *pixels*, de uma mesma categoria, sob um único rótulo. Já a segmentação de instâncias identifica e delimita individualmente cada objeto, ainda que pertençam à mesma classe.

Uma vez que se tenha apresentado o referencial teórico desta pesquisa, a próxima seção detalha o protocolo de pesquisa utilizado.

## 3. Material e Métodos

Para a realização desta pesquisa, o trabalho foi conduzido a partir de um protocolo de pesquisa, desenvolvido pelos autores, que foi organizado em 3 etapas fundamentais: (i) definição das ferramentas de busca utilizadas; (ii) seleção das palavras-chave; e (iii) estabelecimento dos critérios de seleção dos artigos. A fim de se obter a reproduutividade do trabalho, cada uma das etapas é apresentada a seguir.

Na etapa (i), foram escolhidas as ferramentas de busca *Google Acadêmico*, IEEE *Xplore*, *ResearchGate*, Portal de Periódicos da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) e *ScienceDirect*. Os estudos selecionados abrangem o período de 2020 a 2025 – intervalo definido em razão do recente crescimento da utilização de Redes Neurais Profundas na Pecuária de Precisão.

Em seguida, a etapa (ii) consistiu na seleção de um conjunto de palavras-chave em português e inglês: “Visão Computacional”, “Computer Vision”, “identificação de animais”, “animal identification”, “segmentação de animais”, “instance segmentation”, “Zootecnia de Precisão”, “Precision Livestock Farming”, “YOLO”. Além disso, foram consideradas composições entre os termos, como “Visão Computacional” + “Zootecnia de Precisão”. Por fim, a etapa (iii) correspondeu ao processo de triagem dos artigos, a partir de critérios de inclusão, detalhados no Quadro 1.

**Quadro 1. Critérios de Inclusão dos Artigos**

Critérios de Inclusão
1. Artigos que realizaram a identificação e/ou segmentação de animais de produção.
2. Artigos que foram escritos em língua portuguesa ou em língua inglesa.
3. Artigos que utilizaram arquitetura de estado único YOLO para realizar a detecção e/ou segmentação.
4. Artigos que foram realizados <i>inputs</i> de imagens ou vídeos RGB ( <i>Red, Green, Blue</i> ), térmicas ou 3D.
5. Artigos que utilizaram métricas de avaliação de desempenho, como <i>mean Average Precision</i> (mAP), Precisão, <i>Recall</i> , <i>mIoU</i> ou <i>mF1</i> .

Após a aplicação dos critérios estabelecidos, foram identificados 30 artigos. Desse total, 15 foram excluídos por não atenderem aos critérios de inclusão, resultando em 15 estudos para compor a base da revisão (*corpus* da pesquisa)<sup>1</sup>. Ressalta-se que, embora a busca tenha sido realizada em português e inglês, nenhum dos artigos encontrados em língua portuguesa atendeu aos critérios de seleção. Assim, os artigos selecionados foram categorizados em dois grupos: 10 voltados à detecção e, 5, à segmentação de animais – cujos resultados são apresentados na seção a seguir.

## 4. Resultados e Discussão

A partir do mapeamento realizado, foi possível comparar diferentes abordagens sobre detecção e segmentação de animais – as quais são aqui descritas.

### 4.1. Detecção de Animais

A partir desta revisão da literatura foram selecionados 10 artigos<sup>2</sup> sobre detecção de animais de produção, abrangendo espécies como bovinos (vacas leiteiras e de corte), suínos e aves. As bases de dados utilizadas nesses estudos variaram entre 1.031 e 13.223 imagens, empregadas para o treinamento, teste e validação das Redes Neurais.

Predominantemente, os artigos selecionados tiveram como objetivo central o monitoramento dos animais. Segundo Luo *et al.* (2025), essa prática constitui um fator essencial para o bem-estar animal, refletindo diretamente no desempenho produtivo e na eficiência da Pecuária de Precisão. Além disso, a análise em tempo real demonstrou grande importância, pois possibilitou respostas imediatas em situações que afetavam a saúde e o manejo dos animais.

A análise dos artigos de detecção de animais evidenciou, ainda, algumas limitações comuns, especialmente aquelas ligadas às condições de captura das imagens, como iluminação inadequada (Zhang *et al.*, 2025) e sobreposição entre animais (Long *et al.*, 2025). Também se destacou a variação de escala, durante o monitoramento em tempo real – situação em que o animal ora se encontra próximo à câmera, ora mais distante (Li *et al.*, 2024).

<sup>1</sup> Os dados consolidados desta revisão da literatura estão disponíveis em: <https://lnk.dev/h9gId>

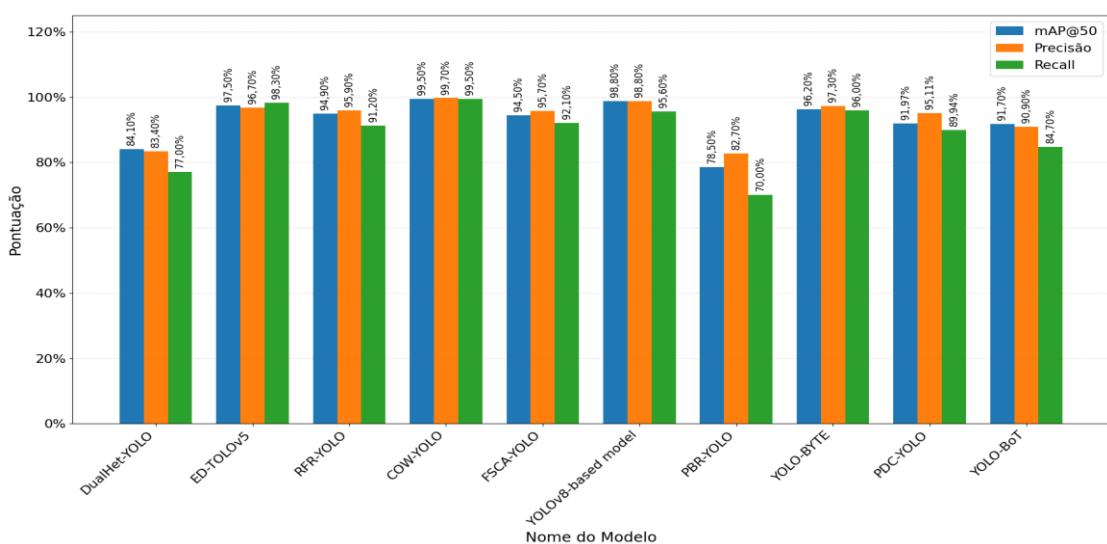
<sup>2</sup> Zhang *et al.* (2025); Cui *et al.* (2023); Li *et al.* (2023); Li *et al.* (2024); Long *et al.* (2025); Elmessery *et al.* (2023); Luo *et al.* (2025); Zheng *et al.* (2023); He *et al.* (2024); Tong *et al.* (2024).

Dentre os algoritmos empregados, os mais recorrentes foram as Redes Neurais Convolucionais e os algoritmos específicos de detecção de animais, com destaque para o YOLO, amplamente aplicado na detecção de objetos em imagens. Cada artigo realizou alterações dentro da arquitetura do YOLO, a fim de solucionar desafios inerentes a cada cenário. Um exemplo é o trabalho de Li *et al.* (2024), que propôs o COW-YOLO, substituindo o *backbone* original (CSPDarcnet53) pelo *Non-local* CSPDarnet53, com o objetivo de identificar o comportamento dos animais, mesmo em ambientes ocluídos – de vacas posicionadas umas atrás das outras.

A pesquisa de Long *et al.* (2025) complementa essa discussão anterior ao apontar dificuldades, como a alta similaridade entre vacas e o fundo de estábulo. Essa característica representa um desafio para os algoritmos de detecção devido ao baixo contraste entre o animal e o ambiente. Para solucionar esse problema, os autores propuseram o FSCA-YOLO, um algoritmo de detecção de múltiplos alvos e reconhecimento de comportamento, que utiliza um módulo de aprimoramento de recursos (*Feature Enhancementet Module-Spatial Context*, FEM-SCAM), permitindo que o modelo se concentre melhor em características comportamentais dos animais.

De maneira análoga, o estudo de Zhang *et al.* (2025) teve como objetivo solucionar um desafio sobre a alta densidade de frangos em granjas, que causava severas oclusões entre as aves. Os autores aprimoraram um algoritmo de YOLO utilizando uma arquitetura com extração de recursos de caminho duplo (*dual-path feature extraction architecture*), que emprega dois *backbones* paralelos para extrair características multinível, garantindo, assim, maior precisão do reconhecimento do comportamento das aves.

Por fim, todos os trabalhos analisados validaram seus modelos por meio de métricas de avaliação de desempenho. As principais métricas utilizadas foram: (i) a Precisão, que mede a exatidão das detecções positivas feitas pelo modelo (Long *et al.*, 2025); (ii) o Recall, que avalia a capacidade do algoritmo encontrar todos os alvos relevantes existentes (He P. *et al.*, 2024); e (iii) o mAP@50, um indicador geral que calcula a precisão média, considerando uma detecção como correta, apenas, se a sobreposição entre a caixa prevista e a real for de, no mínimo, 50% (Luo *et al.*, 2025). O compilado desses resultados (Figura 2) permite comparar a eficiência de cada abordagem aprimorada do YOLO.



**Figura 2. Comparativo das métricas de desempenho de detecção de animais<sup>3</sup>**

<sup>3</sup> Os algoritmos para a criação dos gráficos comparativos estão disponíveis em: <https://l1nk.dev/Wa7jD>

A análise comparativa dessas métricas de desempenho (Figura 2), revela distinções claras entre a eficiência dos algoritmos propostos. Nota-se, que o algoritmo COW-YOLO demonstrou o melhor desempenho, obtendo métricas entre 99,50% (mAP@50 e *Recall*) e 99,70% (Precisão). Em contraposição, o algoritmo PBR-YOLO apresentou 82,70% de Precisão e 70% de *Recall*, o que sugere que este modelo prioriza a exatidão de suas detecções, em detrimento da capacidade de encontrar todos os alvos.

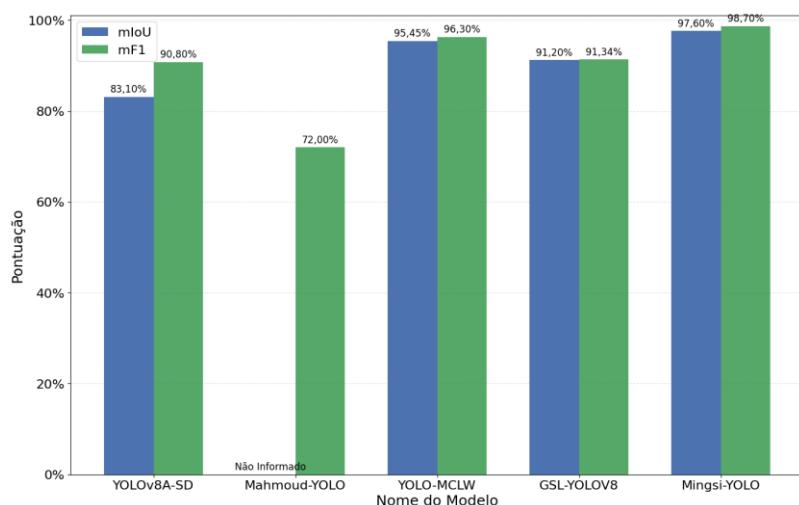
#### 4.2. Segmentação de Animais

Como resultado desta análise foram selecionados 5 artigos<sup>4</sup> que abordam a segmentação de animais de produção, como bovinos, suínos e aves. A base de dados utilizada variou de 1335 a 5751 imagens, sendo utilizadas para treinamento, teste e validação das Redes Neurais.

Notou-se que, o objetivo central desses estudos era obter uma delimitação precisa do corpo do animal, permitindo análises mais detalhadas. Uma delas é a predição de peso, na qual a extração de dados biométricos das imagens (como área do contorno, volume, largura) é fundamental para realizar comparações, por meio de modelos de regressão.

Ademais, um dos principais desafios identificados para a aplicação prática de Visão Computacional, em ambientes rurais, foi a limitação de recursos computacionais *in loco*. O processamento de imagens e a execução de modelos de Aprendizado de Máquina são tarefas que exigem alto poder computacional – infraestrutura, essa, que geralmente não está disponível nas fazendas. Para tratar essa questão, o estudo de Luo *et al.* (2025) propõe um equilíbrio entre desempenho na segmentação de suínos e a eficiência de recursos computacionais dentro das fazendas. Neste trabalho, os autores realizaram um aprimoramento no algoritmo padrão de YOLOv8-seg, resultando em uma arquitetura denominada GSL-YOLOv8.

Para validar a eficácia de suas arquiteturas, os trabalhos de segmentação de animais trouxeram para a discussão a apresentação de algumas métricas de desempenho (as quais constam na Figura 3). Segundo Luo *et al.* (2025), as métricas comumente utilizadas nesta tarefa são a mIoU (*Mean Intersection over Union* – média da interseção sobre a união), que avalia a precisão dos contornos gerados pelo modelo, e o mF1 Score, que calcula a média harmônica das métricas Precisão e *Recall*.



**Figura 3. Comparativo das métricas de desempenho de segmentação de animais**

<sup>4</sup> Sun *et al.* (2024); Shams *et al.* (2025); Liao, M. *et al.* (2025); Liao, Y. *et al.* (2025); Luo *et al.* (2025).

Nesta análise comparativa do desempenho dos modelos de segmentação, o Mingsi-YOLO alcançou a melhor eficiência em relação aos demais (97,60% de mIoU e 98,70% de mF1), seguido pelo YOLO-MCLW (95,45% de mIoU e 96,30% de mF1). Com exceção do Mahmoud-YOLO, os demais algoritmos alcançaram resultados notáveis na tarefa de segmentação de animais. Este alto nível de desempenho pode ser atribuído à metodologia empregada, que combinou o treinamento com imagens originais, com pré-processamento específico para segmentação, durante a fase de teste.

É importante mencionar, ainda, que tanto os artigos de detecção quanto os de segmentação utilizaram uma variedade de *hardwares*, contemplando desde configurações mais robustas (como Intel I9-11900K e RTX 3080) para treinamento, até dispositivos de borda (como Jetson Nano), para aplicações em tempo real.

Em suma, por meio dessa revisão da literatura foi possível constatar que a contribuição dos artigos analisados se concentra, principalmente, no aprimoramento do bem-estar animal e na gestão otimizada. Nesse cenário, o ambiente rural, com suas limitações tecnológicas, impôs um desafio significativo: a necessidade de desenvolver variantes customizadas do algoritmo YOLO. A criação desses modelos resultou em benefícios, como a redução de custos para o produtor rural e maior agilidade em tarefas que, antes, eram realizadas de forma manual. De modo geral, os resultados encontrados são excelentes e apontam para um futuro promissor, com métricas de desempenho que validam a eficácia de cada abordagem – como descrito a seguir.

## 5. Considerações Finais

O presente trabalho apresentou uma revisão da literatura sobre Visão Computacional aplicada à identificação e segmentação de animais. A análise buscou mapear os modelos mais utilizados, consolidar o entendimento sobre a viabilidade dessa tecnologia no cenário da Pecuária de Precisão, identificando tanto barreiras quanto avanços obtidos, nos últimos anos.

A partir dos resultados, foi possível constatar que a Visão Computacional tem ganhado espaço no ambiente rural, principalmente por ser um processo de monitoramento não invasivo e capaz de gerar resultados com alto grau de precisão, se comparado aos métodos manuais, utilizados atualmente.

Durante a pesquisa, uma dificuldade notável foi encontrar artigos de segmentação que utilizassem YOLO como algoritmo e reportassem as métricas definidas (mIoU e mF1). A maioria dos trabalhos encontrados sobre segmentação de animais utilizavam outras arquiteturas como Mask R-CNN, revelando uma lacuna na literatura, que buscou ser explorada neste trabalho, cuja finalidade era investigar os avanços em modelos de um estágio, conhecidos por sua eficiência para aplicações em tempo real. Por essa razão, essa revisão não incluiu uma comparação de métricas entre o YOLO e outros algoritmos, como o Mask R-CNN.

Observou-se, também, que os artigos de detecção e segmentação de animais enfrentam desafios similares, decorrentes das condições de campo. Entre as principais, destacam-se a oclusão entre animais, as condições adversas (como chuva e variações de luminosidade), o baixo contraste entre os animais e o fundo do curral, bem como as limitações de *hardware* para a realização de tarefas em tempo real.

Como perspectiva de trabalhos futuros se mostra promissor duas linhas de pesquisa. A primeira é a integração de técnicas de modelagem temporal (análise de sequências de quadros consecutivos) para capturar a dinâmica temporal, que distingue de forma mais

precisa o comportamento dos animais. A segunda é a fusão de dados de sensores multimodais (como unidades de medição inercial, RFID, sensores ambientais e acústicos) com Visão Computacional, uma estratégia para aumentar a robustez dos sistemas contra os desafios de oclusão, visibilidade e detecção precoce de doenças.

## Referências

- Antognoli, V. et al. (2025) “Computer Vision in Dairy Farm Management: A Literature Review of Current Application and Future Perspectives”, *Animals*, v. 15, n. 17, 2508.
- Berckmans, D. (2017) “General introduction to precision livestock farming”, *Animal Frontiers*, Oxford, v. 7, n. 1, p. 6-11.
- Bernardi, A. C. C. et al. (2022) “Tecnologias de pecuária de precisão para o manejo de pastagens e animais”. In: Agricultura de Precisão: Um novo olhar na era digital. Brasília: Embrapa. p. 623-635.
- Carranza-Garcia, M. et al. (2021) “On the Performance of One-Stage and two-Stage Object Detectors in Autonomous Vehicles Using Camera Data”, *Remote Sensing*, v. 13, n. 89.
- CEPEA – Centro de Estudos Avançados em Economia Aplicada. (2025) “PIB do Agronegócio Brasileiro”. Disponível em: [11nq.com/Lcb4M](http://11nq.com/Lcb4M). Acesso em: 1 out. 2025.
- Cui, Y. et al. (2023) “Research on broiler health status recognition method based on improved YOLOv5”, *Smart Agricultural Technology*, v. 6, 100324.
- Elmessery, W. M. et al. (2023) “YOLO-Based Model for Automatic Detection of Broiler Pathological Phenomena Through Visual and Thermal Images in Intensive Poultry House”, *Agriculture*, v.13, n.8, 1527.
- Goodfellow, I.; Bengio, Y.; Courville, A. (2016) “Deep Learning”, Cambridge: MIT Press.
- He, K. et al. (2017) “R-CNN”. In: IEEE INTERNATIONAL CONFERENCE ON COMPUTER VISION (ICCV), Veneza. *Proceedings* [...]. Veneza: IEEE. p. 2961-2969.
- He, K. et al. (2016) “Deep residual learning for image recognition”. In: IEEE CONFERENCE ON COMPUTER VISION AND PATTERN RECOGNITION (CVPR), Las Vegas. *Proceedings* [...]. Las Vegas: IEEE. p. 770-778
- He, P. et al. (2024) “PDC-YOLO: A Network for Pig Detection Under Complex Conditions for Counting Purposes”, *Agriculture*, v. 14, n. 10, 1807.
- Krizhevsky, A.; Sutskever, I.; Hinton, G. E. (2012) “ImageNet Classification with Deep Convolutional Neural Networks”. In: Conference on Neural Information Processing Systems (NIPS), 2012. Lake Tahoe. *Proceedings* [...]. Lake Tahoe: Curran Associates. p. 1097–1105.
- Lecun, Y.; Bengio, Y.; Hinton, G. (2015) “Deep Learning”, *Nature*, v. 521, n. 7553, p. 436-444.
- Li, C. et al. (2025) “RFR-YOLO-Based Recognition Method for Dairy Cow Behavior in Farming Environments”, *Agriculture*, v. 15, n. 18, p. 1952.
- Li, D. et al. (2024) “Cow-YOLO: Automatic Cow Mounting Detection Based on Non-Local CSPDarknet53 and Multiscale neck”, *International Journal of Agricultural and Biological Engineering*, v. 17, n. 3, p. 193-202.
- Liao, M et al. (2025) “Predicting Dairy Calf Body Weight from Depth Images Using Deep Learning (YOLOv8) and Threshold Segmentation with Cross-Validation and Longitudinal Analysis”, *Animals*, v. 15, n. 6, 868.
- Liao, Y. et al. (2025) “YOLOv8A-SD: A Segmentation-Detection Algorithm for Overlooking Scenes in Pig Farms”, *Animals*, v.15, n.7, 1000.

- Liu, S. *et al.* (2025) "An Improved YOLOv8-Based Lightweight Attention Mechanism for Cross-Scale Feature Fusion", *Remote Sensing*, v. 17, n. 6, 1044.
- Long, T. *et al.* (2025) "FSCA-YOLO: An Enhanced YOLO-Based Model for Multi-Target Dairy Cow Behavior Recognition", *Animals*, v. 15, n. 17, 2631.
- Luo, Y. *et al.* (2025) "A lightweight model for automatic pig counting in intensive piggeries using a green inspection robot and image segmentation method", *Smart Agricultural Technology*, v. 12, 101115.
- Luo, Y. *et al.* (2025) "PBR-YOLO: A Lightweight Piglet Multi-behavior Recognition Algorithm Based on Improved YOLOv8", *Smart Agricultural Technology*, v. 10, 100785.
- Menezes, G. L. *et al.* (2024) "Artificial Intelligence for Livestock: A Narrative review of the Applications of Computer Vision Systems and Large Language models for Animal Farming", *Animal Frontiers*, v. 14, n. 6, p. 43-53.
- Pan, S. J.; Yang, Q. (2010) "A survey on transfer learning", *IEEE Transactions on Knowledge and Data Engineering*, v. 22, n. 10, p. 1345-1359.
- Redmon, J. *et al.* (2016) "You Only Look Once: Unifies, Real Time Object Detection". In: IEEE Conference on Computer Vision and Pattern Recognition (CVPR), Las Vegas. *Proceedings* [...]. Las Vegas: IEEE. p. 779-788.
- Ren, S. *et al.* (2016) "Faster R-CNN: Towards real-time object detection with region proposal networks", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 39, n. 6, p. 1137-1149.
- Ronneberger, O.; Fischer, P.; Brox, T. (2015) "U-Net: Convolutional Networks for Biomedical Image Segmentation". In: INTERNATIONAL CONFERENCE ON MEDICAL IMAGE COMPUTING AND COMPUTER-ASSISTED INTERVENTION (MICCAI), Munique. *Proceedings* [...]. Lecture Notes in Computer Science, v. 9351. Munique: Springer. p. 234–241.
- Shams, M. Y. et al. (2025) "Automated on-site broiler live weight estimation through YOLO-based segmentation", *Smart Agricultural Technology*, v. 10, p. 100828.
- Silva, A. M. *et al.* (2023) "Uso de Inteligência Artificial na Pecuária: Revisão da literatura", *Research, Society and Development*, v.12, n.4 e6612440777.
- Sun, S. *et al.* (2024) "Nondestructive estimation method of live chicken leg weight based on deep learning", *Poultry Science*, v. 103, 103477.
- Tan, M.; Le, Q. V. (2019) "EfficientNet: Rethinking model scaling for convolutional neural networks". In: INTERNATIONAL CONFERENCE ON MACHINE LEARNIG (ICML), 36., Long Beach. *Proceedings* [...]. Long Beach: PMLR. p. 6105-6114.
- Tong, L. *et al.* (2024) "Research on Cattle Behavior Recognition and Multi-Object Tracking Algorithm Based on YOLO-BOT", *Animals*, v. 14, n. 20, 2993.
- Zhang, Y. *et al.* (2025) "DualHet-YOLO: A Dual-Backbone HetoroGeneous YOLO Network for Inspection Robots to Recognize Yellow-Feathered Chicken Behavior in Floor-Raised House", *Agriculture*, v. 15, n.14, 1504.
- Zheng, Z.; Li, J.; Qin, L. (2023) "YOLO-BYTE: An efficient multi-object tracking algorithm for automatic monitoring of dairy cows", *Agriculture*, v. 209, 107857.