

AUTOMATIZAÇÃO DA PESAGEM DE GADO COM VISÃO COMPUTACIONAL E APRENDIZADO DE MÁQUINA: UMA ALTERNATIVA EFICIENTE E NÃO INVASIVA

Vinícius Nuñez Lopes^Ψ
Prof. Dr. Elder de Macedo Rodrigues^Ω

RESUMO

A pecuária brasileira é essencial para a economia, sendo uma das principais responsáveis pela produção de carne. Contudo, a pesagem do gado, indispensável para manejo, comercialização e abate, enfrenta desafios como custos elevados e impactos negativos no bem-estar animal. Métodos tradicionais, como balanças físicas, demandam transporte e causam estresse nos animais. Tecnologias emergentes, como visão computacional e aprendizado de máquina, oferecem soluções inovadoras e não invasivas para estimar o peso do gado. Este estudo apresenta um sistema automatizado para estimar o *live body weight* (LBW) em tempo real, utilizando vídeos 2D com o modelo YOLOv8 e técnicas de visão computacional. O sistema analisa a postura dos animais, extrai parâmetros corporais e os correlaciona com o peso real por meio de sistema linear. A análise apresentou uma precisão de 97%, com erro percentual médio de 1,17%, *Mean Absolute Error* (MAE) de 4,95 kg e *Root-Mean-Square Deviation* (RMSE) de 5,24 kg. O melhor desempenho individual apresentou erro de 0,09% e MAE de 0,37 kg. Um dos principais desafios foi identificar o *frame* ideal para pesagem, utilizando os valores extraídos da segmentação. Além disso, tratativas para cenários adversos, como variações de iluminação, posicionamento incorreto dos animais e interferências externas, foram cruciais para assegurar a robustez do sistema. Esses resultados destacam a viabilidade da solução, representando um avanço significativo no manejo pecuário moderno, com maior confiabilidade, eficiência e sustentabilidade.

Palavras-chaves: Pesagem Automatizada de Gado; Visão Computacional; Aprendizado de Máquina; YoloV8; OpenCV; Eficiência Pecuária.

ABSTRACT

Brazilian livestock farming is essential to the economy, being one of the main contributors to meat production. However, weighing cattle, which is essential for handling, marketing and slaughter, faces challenges such as high costs and negative impacts on animal welfare. Traditional methods, such as physical scales, require transportation and cause stress to the animals. This study presents an automated system for estimating live body weight (LBW) in real time, using 2D videos with the YOLOv8 model and computer vision techniques. The system analyzes the animals' posture, extracts body parameters and correlates them with real weight using a linear system. The analysis was 97% accurate, with an average percentage error of 1.17%, Mean Absolute Error (MAE) of 4.95 kg and Root-Mean-Square Deviation (RMSE) of 5.24 kg. The best individual performance showed an error of 0.09% and MAE of 0.37 kg. One of the

^Ψ Aluno do Curso de Ciência da Computação da Universidade Federal do Pampa, Alegrete, Rio Grande do Sul, Brasil
E-mail: viniciusnunez.aluno@unipampa.edu.br

^Ω Orientador, Professor do Curso de Engenharia de Software da Universidade Federal do Pampa, Alegrete, Rio Grande do Sul, Brasil, E-mail: elderrodrigues@unipampa.edu.br

main challenges was to identify the ideal frame for weighing, using the values extracted from the segmentation. In addition, dealing with adverse scenarios such as lighting variations, incorrect positioning of the animals and external interference were crucial to ensuring the system's robustness. These results highlight the viability of the solution, representing a significant advance in modern livestock management, with greater reliability, efficiency and sustainability.

Keywords: Automated Cattle Weighing; Computer Vision; Machine Learning; YoloV8; OpenCV; Livestock Efficiency.

1. INTRODUÇÃO

A pecuária brasileira, um dos pilares da economia nacional, é reconhecida mundialmente pela sua robusta produção e processamento de carne, contribuindo significativamente para o abastecimento alimentar e a geração de renda. No entanto, o setor enfrenta desafios operacionais, particularmente na pesagem do gado, um processo crítico para o manejo, comercialização e abate eficientes. Tradicionalmente, a pesagem é realizada com balanças físicas, que, apesar de precisas, implicam em custos elevados e estresse para os animais, podendo afetar adversamente tanto o bem-estar quanto a qualidade da carne produzida. A logística de transportar o gado até as balanças também é um desafio, exigindo tempo e recursos consideráveis, especialmente em fazendas extensas (MALHOTRA, 2023; MA, 2024).

Neste contexto, a inovação tecnológica surge como uma solução promissora. A adoção de tecnologias emergentes, como visão computacional e aprendizado de máquina, oferece uma alternativa revolucionária para a pesagem do gado. Esses sistemas avançados permitem estimar o peso dos animais de forma otimizada, não invasiva e econômica, com redução de tempo e estresse, representando uma mudança significativa em relação aos métodos convencionais. Assim, o objetivo deste estudo é desenvolver um modelo de estimativa automática do LBW do gado em tempo real, baseado em vídeos 2D e 3D, utilizando o modelo YOLOv8 e técnicas de visão computacional para capturar a postura e identificar os animais, a fim de extrair parâmetros corporais para estabelecer um modelo de sistema linear que correlacione essas medidas com o LBW real medido (CASTILLO et al., 2022).

1.1. MOTIVAÇÃO

A pesagem de gado no Brasil desempenha um papel essencial para a eficiência da pecuária, sendo um processo que exige investimentos substanciais, tanto financeiros quanto logísticos, para a instalação e manutenção das balanças tradicionais. Contudo, além dos custos, esse processo muitas vezes impõe desafios adicionais, como o estresse causado aos animais, que pode afetar negativamente seu bem-estar e comprometer a qualidade da carne, resultando até mesmo em perda de peso. O transporte do gado até as balanças, especialmente em fazendas de grande porte, torna-se ainda mais complexo, demandando recursos consideráveis e tempo significativo.

Diante desses obstáculos, é fundamental a busca por uma metodologia de pesagem mais eficiente e econômica, que minimize os impactos negativos e maximize os benefícios operacionais. Nesse contexto, a integração de tecnologias emergentes,

como YOLOv8 e OpenCV, no campo do aprendizado de máquina e visão computacional, surge como uma solução inovadora e promissora. Esses sistemas avançados possibilitam a identificação precisa dos animais e, através de algoritmos sofisticados, permitem a obtenção de métricas corporais essenciais para calcular o Peso Corporal Vivo (LBW) de maneira otimizada e não invasiva. A utilização dessas tecnologias oferece a possibilidade de automatizar o processo de pesagem, reduzindo o tempo necessário e aumentando a precisão dos resultados, o que representa um avanço significativo em relação aos métodos tradicionais, com o potencial de impulsionar a transformação digital no setor pecuário (MA et al., 2024).

1.2. PROBLEMA

As práticas atuais de pesagem de gado, dependentes de balanças mecânicas ou eletrônicas, enfrentam desafios substanciais. Estes incluem altos custos operacionais e logísticos, além de causarem estresse nos animais, o que pode resultar em perda de peso e afetar a precisão das medições, diminuindo o valor de mercado do gado. O transporte e manejo dos animais para a pesagem são processos ineficientes e onerosos (PENG et al., 2024).

Tecnologias baseadas em visão computacional e aprendizado de máquina oferecem uma solução eficiente e não invasiva. A implementação de um sistema automatizado utilizando essas ferramentas pode melhorar significativamente o gerenciamento pecuário, reduzir custos operacionais, promover o bem-estar animal e aumentar a produtividade. Essa inovação é especialmente benéfica para fazendas de pequeno e médio porte, que frequentemente enfrentam desafios financeiros e tecnológicos para adotar soluções mais sofisticadas.

1.3. OBJETIVOS

Objetivo Geral

Desenvolver um sistema automatizado de pesagem de gado, utilizando metodologias eficazes e não invasivas, com base em tecnologias avançadas como YOLOv8 e OpenCV, para otimizar a gestão pecuária.

Objetivos Específicos

- Alcançar um elevado nível de precisão na pesagem, assegurando margens de erro aceitáveis;
- Garantir a confiabilidade e a consistência dos dados coletados durante o processo de pesagem;
- Promover equidade nas negociações comerciais que utilizam o peso dos animais como parâmetro principal;
- Disponibilizar uma solução acessível e economicamente viável, especialmente para propriedades rurais de pequeno e médio porte;
- Contribuir para o bem-estar animal, eliminando a necessidade de métodos invasivos e minimizando o estresse dos animais.

Com essa abordagem, espera-se não apenas melhorar a eficiência e sustentabilidade no manejo pecuário, mas também garantir maior transparência nas transações comerciais, promover a qualidade da carne e assegurar o bem-estar dos animais de forma inovadora e prática.

1.4. ORGANIZAÇÃO

O presente estudo foi estruturado da seguinte maneira:

A Seção 2 apresenta o referencial teórico do estudo, abordando conceitos de visão computacional e aprendizado de máquina, além de discutir as ferramentas utilizadas e os trabalhos relacionados ao tema. Em seguida, a Seção 3 detalha a implementação da ferramenta para pesagem autônoma de gado. A Seção 4 apresenta os resultados obtidos. Por fim, a Seção 5 traz as conclusões preliminares do trabalho e o cronograma de atividades proposto.

2. FUNDAMENTAÇÃO TEÓRICA

Esta seção aborda os conceitos fundamentais relacionados ao estudo, explorando a importância da pecuária na economia global e brasileira, os desafios dos métodos tradicionais de pesagem de gado e a proposta de utilização de tecnologias inovadoras como visão computacional, processamento de imagens digitais e aprendizado de máquina. A visão computacional permite que sistemas extraiam informações úteis de imagens e vídeos, enquanto o processamento de imagens digitais envolve técnicas para manipular e aprimorar essas imagens. O aprendizado de máquina utiliza algoritmos para identificar padrões e fazer previsões a partir dos dados visuais. Juntas, essas tecnologias prometem transformar a prática da pesagem de gado, oferecendo uma alternativa não invasiva, precisa e economicamente viável às balanças físicas tradicionais.

2.1. VISÃO COMPUTACIONAL

A visão computacional, conforme definida por (BALLARD; BROWN, 1982), é o campo da ciência que estuda e desenvolve tecnologias para capacitar máquinas a perceber e extrair características de imagens digitais obtidas por diversos sensores e dispositivos. Esse processo envolve a extração de informações por meio de operações ou transformações aplicadas a dados como imagens digitais, vídeos ou estruturas de dados multidimensionais do mundo real (GARCÍA et al., 2015).

Na pecuária, essa tecnologia pode ser aplicada de maneira não invasiva e eficiente no processo de pesagem de gado (BRASIL, 2024). Ao simular o aprendizado humano na interpretação de informações visuais, utiliza técnicas avançadas de Processamento Digital de Imagens (PDI) e algoritmos de Aprendizado de Máquina (AM) para reconhecer, manipular e processar dados dos objetos presentes em imagens capturadas (LIMA; GOMES, 2015).

O processo de aquisição de imagens que envolve a captura por meio de uma câmera conectada ao Raspberry Pi, garantindo um formato adequado para manipulação. Nesta etapa, são configurados parâmetros como formato da imagem digital, configurações de luminosidade e resolução (FOUNDATION, 2023). No pré-processamento, o foco está na melhoria da qualidade da imagem capturada. São aplicadas técnicas

para redução de ruídos, ajuste de contraste e brilho, e equalização de histograma. Após essa etapa, segue-se à segmentação, que consiste em separar a imagem em regiões de pixels similares (SONKA; HLAVAC; BOYLE, 2014).

Portanto, a implementação de um sistema automatizado de pesagem para gado torna-se uma solução eficaz e não invasiva. Tal sistema representa uma alternativa viável às balanças tradicionais, com suas altas despesas de aquisição e manutenção, além do estresse causado aos animais e da complexidade logística envolvida. A visão computacional emerge como uma solução inovadora e eficiente, transformando a prática da pesagem de gado e alinhando-se aos objetivos de modernização e sustentabilidade do setor agropecuário.

2.1.1. PROCESSAMENTO DE IMAGENS DIGITAIS

Segundo (GONZALEZ; WOODS, 2018) processamento de imagens digitais (PDI) é uma disciplina da ciência da computação dedicada à melhoria e análise de imagens digitais por meio de diversos algoritmos e técnicas. Estas incluem ajustes como brilho, contraste, nitidez e cores. No sensoriamento remoto, dados multidimensionais são coletados por sensores em órbita ou suborbitais em satélites, aviões, balões e drones. A representação fundamental das cores no PDI inclui o formato RGB (Red, Green e Blue), ideal para monitores, e CMYK (Cyan, Magenta, Yellow e Black), utilizado na impressão (GONZALEZ; WOODS, 2018).

A binarização é uma técnica básica em PDI que converte imagens coloridas ou em tons de cinza em imagens binárias (preto e branco) definindo um limiar para separar intensidades de cor convertidas em preto ou branco. Esta técnica é essencial para preparar imagens para processamentos adicionais como reconhecimento de padrões e análise de texto (GONZALEZ; WOODS, 2018).

Os filtros são ferramentas vitais em PDI, permitindo operações como suavização, realce e detecção de bordas. Filtros como o gaussiano reduzem ruídos, enquanto o operador Sobel destaca bordas na imagem, essencial para melhorar a aparência visual ou para análises mais complexas (GONZALEZ; WOODS, 2018).

As redes neurais convolucionais (CNNs), parte do campo do aprendizado profundo, representam um avanço notável em PDI ao aprender automaticamente características relevantes das imagens. Isso elimina a necessidade de intervenção humana na definição de filtros, sendo aplicadas com sucesso em reconhecimento facial, segmentação semântica e na indústria automotiva com veículos autônomos. Assim, o PDI continua a evoluir como uma área dinâmica da ciência da computação com aplicações transformadoras no mundo digital (GONZALEZ; WOODS, 2018).

2.2. APRENDIZADO DE MÁQUINA

O aprendizado de máquina (ML) é um ramo da inteligência artificial (IA) e da ciência da computação que se concentra no uso de dados e algoritmos para permitir que a IA imite a maneira como os humanos aprendem (MITCHELL, 1997). Em vez de serem explicitamente programados, os sistemas de ML são projetados para aprender a partir dos dados, o que lhes permite fazer previsões sobre eventos futuros, classificar dados em diferentes categorias, detectar anomalias e executar muitas outras tarefas que estão além das capacidades dos sistemas tradicionais baseados em regras pré-programadas. Essa capacidade de aprendizado e adaptação torna o aprendizado de

máquina uma ferramenta poderosa para transformar dados brutos em insights valiosos, impulsionando inovações em diversas áreas da tecnologia e ciência (ONE, 2024).

Abordaremos conceitos fundamentais do aprendizado de máquina, incluindo suas principais abordagens: a aprendizagem supervisionada e não supervisionada, além da aprendizagem profunda e das redes neurais convolucionais. A aprendizagem supervisionada se baseia em dados rotulados para treinar modelos a fazer previsões, enquanto a aprendizagem não supervisionada busca identificar padrões ocultos em dados não rotulados (IBM, 2024). A aprendizagem profunda utiliza redes neurais profundas para resolver problemas complexos, e as redes neurais convolucionais são particularmente eficazes no processamento de dados estruturados em grade, como imagens (ONE, 2024). Compreender essas técnicas é crucial para aplicar o aprendizado de máquina de maneira eficaz em diversos contextos, incluindo a proposta de soluções inovadoras e eficientes para a pesagem de gado na pecuária.

2.2.1. APRENDIZAGEM SUPERVISIONADA E NÃO-SUPERVISIONADA

A aprendizagem supervisionada e a não supervisionada são abordagens essenciais no aprendizado de máquina, cada uma com características e aplicações distintas, mas ambas desempenham um papel crucial no desenvolvimento de modelos inteligentes.

A **aprendizagem supervisionada** é a abordagem mais comum e amplamente utilizada. Nesse método, os algoritmos são treinados utilizando um conjunto de dados rotulado, ou seja, para cada entrada fornecida ao modelo, existe uma saída correspondente já conhecida. O objetivo é ensinar o modelo a prever ou classificar novos dados com base no aprendizado das relações entre as entradas e suas saídas associadas. Isso é particularmente útil em tarefas como reconhecimento de padrões, classificação de imagens, e previsão de valores contínuos, como no caso da regressão. A principal vantagem dessa abordagem é que ela permite treinar modelos com alta precisão, já que os rótulos fornecem a "resposta correta" durante o processo de aprendizado. No entanto, um desafio é a necessidade de grandes volumes de dados rotulados, o que pode ser caro ou difícil de obter em muitos casos (LUDERMIR, 2021).

Por outro lado, a **aprendizagem não supervisionada** lida com dados não rotulados, onde o objetivo do modelo é identificar padrões e estruturas subjacentes nos dados sem a necessidade de rótulos explícitos. Os algoritmos de aprendizagem não supervisionada são frequentemente utilizados para tarefas como clustering, onde o modelo agrupa os dados em clusters baseados em similaridades entre os exemplos, ou redução de dimensionalidade, como na análise de componentes principais (PCA). Essa abordagem é útil quando não se tem acesso a dados rotulados ou quando se deseja explorar os dados de forma mais livre, descobrindo relacionamentos que não são imediatamente óbvios. No entanto, a falta de rótulos pode tornar a avaliação do desempenho do modelo mais difícil e, frequentemente, exige interpretação humana dos resultados obtidos (LUDERMIR, 2021).

Ambas as abordagens têm suas vantagens e limitações, e frequentemente, técnicas híbridas ou complementares podem ser utilizadas para melhorar a eficácia do aprendizado de máquina em diversas situações. A escolha entre uma ou outra depende do tipo de problema a ser resolvido, da disponibilidade de dados rotulados e dos objetivos específicos do projeto.

2.2.2. APRENDIZAGEM PROFUNDA

O aprendizado profundo é uma técnica avançada aplicada em Redes Neurais Artificiais, com o objetivo de replicar o funcionamento do cérebro humano, permitindo que sistemas computacionais aprendam a partir de grandes volumes de dados (FILHO, 2023). Devido à grande quantidade de camadas intermediárias presentes nas redes neurais profundas, é necessário um ajuste específico na configuração para garantir sua rápida convergência e desempenho otimizado. Essa abordagem é particularmente eficaz em tarefas que envolvem dados não rotulados, onde a precisão e a capacidade de generalização são essenciais (DENG; YU et al., 2014). No contexto da pesagem de gado, o aprendizado profundo pode ser utilizado para desenvolver sistemas mais precisos e eficientes, que estimam o peso dos animais a partir de imagens coletadas em tempo real.

Modelos de aprendizado profundo, como redes neurais convolucionais (CNNs), são capazes de identificar e analisar características específicas dos animais, como contornos corporais e proporções, possibilitando a estimativa do peso com alta precisão. Esse processo envolve múltiplas camadas de redes neurais que trabalham em conjunto, interpretando os dados visuais de maneira semelhante à percepção humana. Com a disponibilidade de grandes conjuntos de dados e o poder computacional proporcionado por GPUs e serviços de computação em nuvem, esses modelos podem ser treinados para alcançar um nível de precisão excepcional (LECUN; BENGIO; HINTON, 2015).

Uma das principais vantagens do aprendizado profundo é sua capacidade de aprender e melhorar continuamente com o treinamento de novos dados. Isso permite que o sistema se adapte a diferentes condições e variações entre os animais, mantendo sua precisão em uma variedade de contextos. A flexibilidade do sistema é fundamental para garantir que a pesagem de gado seja realizada de forma eficiente, independentemente das condições de iluminação, dos ângulos das câmeras e das características individuais dos animais.

A aplicação de modelos de aprendizado profundo na pesagem de gado oferece uma solução não invasiva, altamente precisa e eficaz, que pode transformar o manejo pecuário. Além de reduzir o estresse dos animais, essa abordagem otimiza a logística operacional, proporcionando uma maneira mais eficiente de gerenciar a pesagem. Essa tecnologia tem o potencial de impulsionar a eficiência e sustentabilidade da indústria pecuária, promovendo uma produção mais eficaz e responsável (VIANA, 2024).

2.2.3. REDES NEURAS CONVOLUCIONAIS

As Redes Neurais Convolucionais (CNNs) representam uma categoria específica de redes neurais profundas desenvolvidas para processar dados estruturados em grade, como imagens e séries temporais, utilizando camadas convolucionais (GU et al., 2018). Elas desempenham um papel fundamental na visão computacional, sobressaindo-se em tarefas como classificação de imagens e reconhecimento de objetos. A estrutura de uma CNN compreende várias camadas, cada uma com uma função específica: a Camada Convolutiva, que identifica padrões locais na imagem; a Camada de *Pooling*, que reduz a dimensionalidade da imagem mantendo características importantes; e a Camada Totalmente Conectada (FC - *Fully Connected Layer*),

que combina informações das camadas anteriores para a classificação final (GU et al., 2018).

O funcionamento de uma CNN tem como ponto central a camada convolucional, que constitui o bloco fundamental da arquitetura. Essa camada emprega filtros (ou kernels) para identificar características relevantes da imagem. À medida que os dados da imagem atravessam as várias camadas da CNN, a rede vai identificando elementos mais complexos do objeto, partindo de características simples, como cores e bordas, até chegar à identificação completa do objeto. As CNNs apresentam diversas vantagens, tais como a capacidade de extrair automaticamente características, a invariância a translações e a eficiência computacional, o que as torna aplicáveis em uma ampla gama de campos, desde o diagnóstico médico até o desenvolvimento de veículos autônomos, impulsionando avanços significativos em tecnologia e ciência. Além disso, as redes neurais convolucionais interpretam imagens como volumes tridimensionais, percebendo-as como objetos em vez de estruturas planas, e por meio de operações matemáticas complexas, são capazes de gerar probabilidades para diferentes classes de saída, contribuindo assim para avanços significativos em visão computacional e em outras áreas correlatas.(AGHDAM; HERAVI, 2017)

A representação esquemática da CNN, conforme ilustrada na Figura 1, destaca seus principais componentes e o fluxo de dados. Inicialmente, as camadas de convolução e pooling são responsáveis por extrair características relevantes da imagem de entrada, detectando bordas, texturas e padrões importantes. Em seguida, as camadas totalmente conectadas utilizam conexões complexas entre os neurônios para processar essas características e realizar a classificação. A camada de saída, por sua vez, determina a classe da imagem com base nas probabilidades associadas a cada categoria, como "bird", "dog" e "cat", como exemplificado no diagrama. Por fim, a imagem de entrada percorre todas essas etapas da rede, culminando na previsão final da classe da imagem.

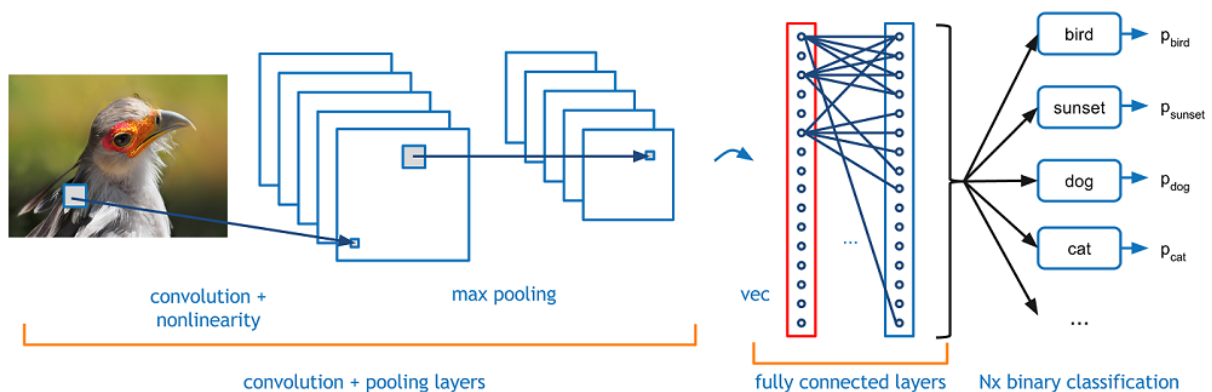


Figura 1 - Redes Neurais Convolucionais (BOOK, 2017).

2.3. BIBLIOTECAS E FERRAMENTAS

Na área de visão computacional e aprendizado de máquina, a seleção das ferramentas adequadas desempenha um papel crucial no sucesso de um projeto. A escolha correta das tecnologias impacta diretamente na eficiência, precisão e viabilidade das soluções desenvolvidas. Nesta seção, exploraremos duas ferramentas

amplamente utilizadas que desempenham papéis fundamentais no desenvolvimento de soluções avançadas: YOLOv8 e OpenCV.

2.3.1. YOLOv8

O YOLOv8 (You Only Look Once) é uma das mais recentes e poderosas arquiteturas de detecção de objetos em tempo real, desenvolvida pela Ultralytics ¹. Com uma capacidade excepcional para identificar e localizar objetos em imagens e vídeos rapidamente, o YOLOv8 se destaca pela sua eficiência e precisão. Ele utiliza redes neurais convolucionais profundas (CNNs) treinadas para reconhecer padrões complexos em grandes volumes de dados visuais. Sua arquitetura permite a detecção de múltiplos objetos em uma única passagem pela imagem, tornando-o ideal para aplicações que exigem alta velocidade, como sistemas de vigilância, veículos autônomos e reconhecimento facial. Sua habilidade de processar dados em tempo real com baixa latência e alta taxa de acerto é um diferencial significativo, tornando-o amplamente utilizado em diferentes setores.

A combinação do YOLOv8 com outras ferramentas como o OpenCV amplia ainda mais sua aplicação, proporcionando uma plataforma robusta para o desenvolvimento de soluções avançadas de visão computacional. O OpenCV, por exemplo, pode ser utilizado para pré-processamento de imagens, captura de vídeo e outras manipulações de dados visuais, complementando a detecção realizada pelo YOLOv8. Essa integração permite a criação de sistemas inovadores, como no caso da detecção e monitoramento de animais em tempo real, o que tem grande potencial no setor agropecuário, otimizando processos como a pesagem de gado de maneira não invasiva e sem causar estresse aos animais. Assim, o YOLOv8 não apenas transforma a forma como lidamos com a visão computacional, mas também abre novas possibilidades para aplicações industriais e comerciais.

2.3.2. OPENCV

O OpenCV (Open Source Computer Vision Library) é uma plataforma composta por um conjunto de bibliotecas de código aberto, desenvolvidas para facilitar o desenvolvimento de softwares de visão computacional e aprendizado de máquina. Originalmente criado pela Intel, o OpenCV foi projetado para fornecer uma infraestrutura comum para aplicações de visão computacional, tanto para pesquisa quanto para uso comercial. As bibliotecas do OpenCV possuem algoritmos otimizados que permitem uma ampla gama de funcionalidades, como detecção e reconhecimento de faces, identificação de objetos, classificação de ações humanas em vídeos, movimentação de câmeras e objetos, construção de modelos 3D e trabalhos com visão estéreo, entre outras tarefas relacionadas à visão computacional (BARELLI, 2018).

O OpenCV inclui implementações para diversas técnicas de processamento digital de imagem, como transformação de espaço de cores e detectores de borda, que são fundamentais para uma variedade de aplicações (VETRISILVAN; STALIN, 2017). Oferecendo recursos para diversas tarefas, desde a detecção de objetos e reconhecimento facial até a calibração de câmeras e a manipulação de imagens, sua flexibilidade e facilidade de uso tornam o OpenCV uma escolha popular entre os desenvolvedores que buscam soluções robustas e escaláveis em visão computacional.

¹ <<https://docs.ultralytics.com/>>

2.4. TRABALHOS RELACIONADOS

Nesta seção, apresentamos uma análise de estudos relevantes encontrados na literatura que compartilham aspectos semelhantes com o nosso projeto. Focamos em métodos e técnicas aplicadas à predição de peso de gado, com ênfase em abordagens baseadas em visão computacional e aprendizado de máquina. Esses trabalhos oferecem uma base comparativa que nos permite identificar pontos fortes e limitações, os quais influenciaram o desenvolvimento da nossa solução. Ao examinar essas abordagens, conseguimos contextualizar melhor a inovação e os benefícios do nosso projeto, destacando sua contribuição para a modernização e maior eficiência na gestão pecuária.

A Tabela 1 compara nosso projeto com estudos da literatura sobre predição de peso de gado, destacando as técnicas, algoritmos, vantagens e métricas de cada abordagem. A comparação evidencia as inovações e melhorias do nosso modelo, especialmente no contexto da pecuária brasileira.

Tabela 1 - Comparação de Abordagens para Predição de Peso Corporal em Bovinos.

Estudo	Técnicas e Algoritmos	Características e Vantagens	Métricas Obtidas
Predição inteligente de peso baseada em segmentação semântica e rede neural BP	ResNet-101-D com Squeeze-and-Excitation (SE); Rede Neural de Retropropagação	Características morfológicas detalhadas de vacas capturadas; melhoria no bem-estar animal	MAE: 13,11 libras; RMSE: 22,73 libras (B, 2024)
Sistema automático para gado coreano com algoritmo Bayesian Ridge e RGB-D	Segmentação e correção de postura com imagens RGB-D; Bayesian Ridge e Random Forest	Precisão na segmentação e extração de características corporais, ideal para sistemas embarcados	Melhor modelo: Floresta Aleatória; otimizado: Bayesian Ridge (NA et al., 2022)
Método dinâmico de estimativa de peso para iaques usando YOLOv8	YOLOv8 para detecção de parâmetros corporais em tempo real	Alta precisão, ideal para monitoramento diário de peso em grandes fazendas	mAP50: 99,0%; eficaz especialmente para iaques (PENG et al., 2024)
Estimativa de peso com modelo 3D PointNet++ para bovinos de corte	Modelo 3D PointNet++ com nuvem de pontos (PCD) tridimensional	Estimativa precisa sem contato físico; robustez para diferentes conformações corporais	MAPE: 3,2%; RMSE: 10,2 kg (HOU et al., 2023)
Nosso Projeto	YOLOv8 com redes neurais convolutivas e OpenCV	Modelo otimizado com menos camadas, precisão entre 93% e 99%, adaptado para cenários brasileiros	mAP50: 99,0%; MAE: 4,95%; resultados obtidos no cenário proposto

3. IMPLEMENTAÇÃO

Para desenvolver essa ferramenta de automatização para a pesagem de gado, empregamos tecnologias emergentes nos campos de visão computacional e aprendizado de máquina. Este sistema de pesagem busca integrar tecnologias de ponta, como YOLOv8, OpenCV, a fim de fornecer uma solução inovadora e não invasiva para a gestão do rebanho. Durante esta jornada, exploraremos diversas etapas cruciais, desde a criação e preparação do conjunto de dados até a análise dos resultados preliminares obtidos após a detecção de peso pelo modelo.

A topologia ilustrada na Figura 2 foi concebida para desvendar a interação entre os diversos componentes disponíveis, como dispositivos de captura e tecnologias de programação, que são utilizados na detecção e segmentação de gado por meio da rede YOLOv8 e OpenCV. O fluxograma expõe o emprego desses dispositivos e a inter-relação entre eles no contexto da aplicação. A “Entrada de Dados” é realizada por duas fontes principais: uma câmera e um Raspberry Pi, que capturam os

dados necessários para a aplicação. Estes são então processados pelas “dependências” disponíveis, que englobam Python 3.12, OpenCV e YOLOv8, essenciais para o tratamento dos dados. Após o processamento, os dados são direcionados para as aplicações do usuário, permitindo a visualização das informações obtidas pelos dispositivos.

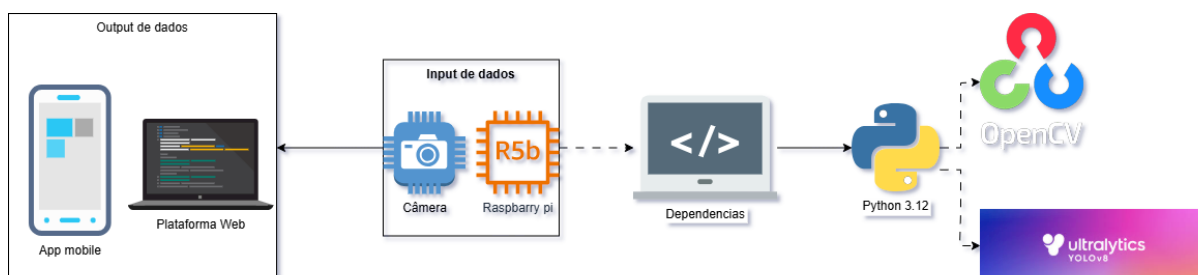


Figura 2 - Topologia da Aplicação.

No processo, temos como marco inicial a criação e organização do conjunto de dados, assegurando que ele seja representativo e adequado para o treinamento do modelo. Em seguida, é apresentado o processo de pré-processamento dos dados e a geração do modelo, aproveitando as poderosas ferramentas disponíveis no OpenCV e YOLOv8. Discutiremos a integração dessas tecnologias para criar um modelo preciso e confiável, capaz de identificar e rastrear os animais em tempo real.

Após a fase de modelagem, será realizada a etapa de predição de peso, na qual usaremos o sistema desenvolvido para calcular com precisão o peso de cada animal. Investigaremos os desafios encontrados nesta fase e as soluções adotadas para garantir resultados precisos e consistentes. Por fim, examinaremos os resultados obtidos, destacando as melhorias na eficiência operacional, no bem-estar dos animais e na gestão do rebanho proporcionadas pelo sistema de pesagem automatizada.

3.1. METODOLOGIA

A metodologia adotada neste estudo é meticulosamente delineada em etapas sequenciais e interconectadas, com o objetivo de desenvolver um sistema automatizado de pesagem de gado robusto e confiável, baseado em tecnologias avançadas de visão computacional e aprendizado de máquina para análise e processamento de imagens. O processo começou com a definição dos requisitos, a seleção de tecnologias e o auxílio de uma revisão sistemática da literatura, o que nos permitiu identificar as ferramentas mais adequadas para alcançar os objetivos de segmentação dos objetos e predições propostos neste trabalho.

Como pode ser visto na Figura 3, o processo de desenvolvimento foi dividido em:

- **Concepção**

- **Definição dos Requisitos:** Esta fase inicial envolve um planejamento detalhado onde são estabelecidos os requisitos essenciais do sistema. A precisão, usabilidade, custo e durabilidade são considerados para assegurar que o sistema atenda às necessidades práticas do setor pecuário.

- **Decisões de Design:** Nesta fase, são tomadas decisões críticas sobre a arquitetura do sistema, interfaces de usuário e a seleção de hardware e software, garantindo que o design atenda tanto aos requisitos técnicos quanto às expectativas dos usuários finais.
- **Identificação das ferramentas de Implementação**
 - **Revisão Ad-hoc da Literatura:** Por meio de uma revisão informal e direcionada da literatura existente, identificamos lacunas de pesquisa, tendências tecnológicas e melhores práticas no campo da visão computacional e aprendizado de máquina aplicados à pecuária.
 - **Seleção de Tecnologias:** Identificação e escolha das tecnologias mais adequadas para segmentação de objetos e predições, considerando as necessidades específicas do projeto de um modelo de pesagem de gado.
- **Implementação**
 - **Dataset e Modelo:** Seleção e preparação de conjuntos de dados representativos para treinar e testar os modelos de aprendizado de máquina. Desenvolvimento de um modelo que possa identificar e pesar o gado com precisão.
 - **Desenvolvimento dos Algoritmos:** Nesta etapa, algoritmos de aprendizado de máquina são criados e treinados para reconhecer e pesar os animais. O foco é na acurácia em tempo real, permitindo que o sistema responda dinamicamente ao ambiente de fazenda.
- **Avaliação**
 - **Análise dos Dados:** Os dados coletados durante os testes são analisados para ajustar e calibrar os algoritmos, garantindo que o sistema funcione conforme o esperado em diversas condições e com diferentes tipos de gado.
 - **Análise dos Resultados:** Avaliação detalhada dos dados coletados durante os testes, ajustando e calibrando os algoritmos para garantir precisão e confiabilidade. A análise considera diferentes condições ambientais e variações nos tipos de gado, assegurando um desempenho robusto e consistente do sistema.

Esta metodologia reflete um processo sistemático e iterativo, garantindo a integração efetiva das tecnologias e a funcionalidade do sistema proposto conforme.

3.2. DATASET

Uma etapa crucial no desenvolvimento do sistema de pesagem automatizada para gado é a seleção e preparação adequada do conjunto de dados utilizados para treinar e testar o modelo. Optamos por utilizar o Roboflow, uma plataforma que permite gerar o conjunto de dados de forma eficiente, otimizando o processo de segmentação dos objetos e facilitando a separação das imagens para treinamento, validação e teste.

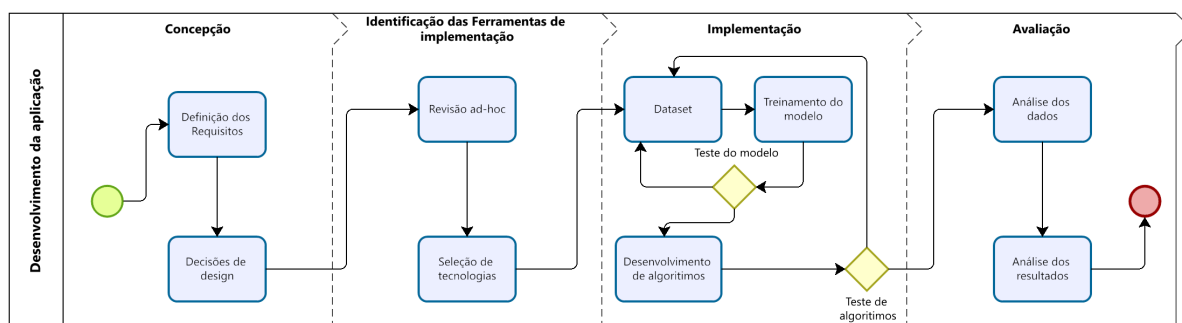


Figura 3 - Processo adotado no desenvolvimento do trabalho.

Inicialmente, as imagens do conjunto de treinamento foram selecionadas para abranger uma ampla gama de variações, como diferentes raças, idades, tamanhos, poses dos animais e fundos variados. Essas imagens foram coletadas em diversos ambientes de criação, considerando condições reais de uso do sistema, com mudanças na iluminação, texturas de solo e presença de outros objetos no cenário, conforme ilustrado na Figura 4. Esse conjunto de dados inicial apresentou bons resultados durante o treinamento do primeiro modelo.

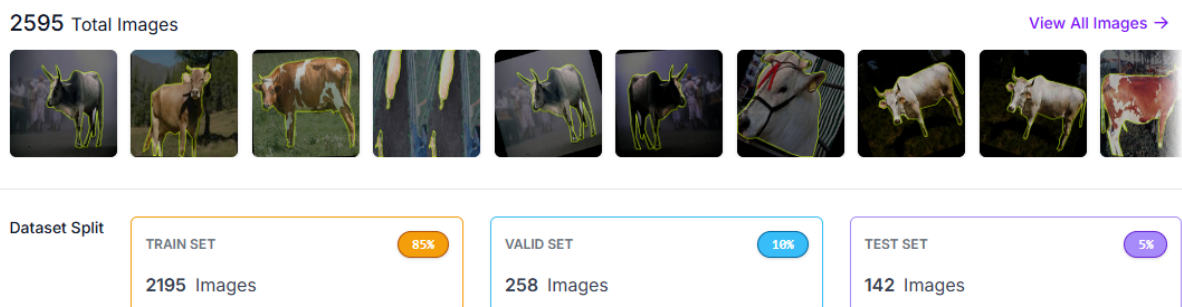


Figura 4 - Dataset Versão 1.

No entanto, para que o sistema se torne mais robusto, foram adicionadas imagens que capturam a variabilidade dos cenários encontrados em condições reais, como ilustrado na Figura 5. Esse novo conjunto de dados foi segmentado com maior precisão, refletindo melhor os ambientes de criação de gado em que o sistema de pesagem será implantado. Com isso, buscou-se garantir que o modelo fosse eficaz na segmentação e análise do objeto-alvo, mesmo em cenários complexos e dinâmicos.

Contudo, ao aplicar o modelo treinado em ambientes reais, identificamos que sua eficácia na segmentação e detecção dos animais não se mantinha com a mesma qualidade observada nos testes. O desempenho divergia consideravelmente das taxas de acurácia obtidas no treinamento, mostrando-se insuficiente para uma segmentação precisa e confiável. Essa disparidade nos resultados levou à conclusão de que o conjunto de dados, embora diversificado, não era suficientemente para a aplicação.

Diante dessa observação, foi decidido reestruturar o conjunto de dados desde o início. Na criação do novo dataset, representado na Figura 6, optou-se por incluir imagens capturadas em condições reais, explorando variados ângulos, iluminação e cenários semelhantes aos que o sistema enfrentaria. Esse novo conjunto de dados




Figura 5 - Ilustração dos cenários e Segmentação versão 1.




Figura 6 - Dataset Versão 2.

recebeu um tratamento mais específico para as classes, de modo que o modelo pudesse diferenciar com mais precisão os elementos do cenário, como partes do corpo dos animais e objetos ao redor, resultando em uma segmentação mais precisa e permitindo uma extração de parâmetros de maior qualidade. Na Figura 7, observa-se uma segmentação que demonstra uma identificação mais eficaz do objeto, evidenciando o aprimoramento do novo modelo para identificar e segmentar corretamente o gado.

Com esse conjunto de dados atualizado, o modelo foi ajustado para lidar melhor com os desafios encontrados em situações reais, aprimorando sua robustez e eficiência na detecção e análise dos animais. A diversidade e representatividade desse dataset proporcionam ao modelo a capacidade de oferecer resultados mais precisos e confiáveis em ambientes complexos e dinâmicos de criação de gado, promovendo, assim, uma gestão mais eficiente e sustentável do rebanho.

3.3. PRÉ-PROCESSAMENTO

Durante a etapa de pré-processamento, as imagens dos dois conjuntos de dados passaram por operações essenciais para adequar-se aos requisitos da rede neural convolucional (RNC) e maximizar o desempenho dos modelos. No primeiro conjunto de dados, que incluiu uma ampla variedade de poses, iluminação e cenários, as imagens foram redimensionadas para 640 x 640 pixels utilizando a plataforma Roboflow.



Figura 7 - Ilustração do cenário e segmentação versão 2.

Esse redimensionamento padronizou o formato das imagens e reduziu a carga computacional, facilitando o processamento pelo modelo.

A padronização para 640 x 640 pixels foi estratégica para balancear a qualidade e o desempenho computacional. Um tamanho menor poderia comprometer a precisão da segmentação em detalhes finos dos animais, enquanto um tamanho maior aumentaria a carga computacional, sem ganhos proporcionais em precisão. Esse tamanho fixo também simplificou o processamento em lote, eliminando ajustes dinâmicos de dimensionamento durante a execução.

Para enriquecer ainda mais os conjuntos, aplicamos *data augmentation* (aumento de dados), com transformações como rotação, espelhamento, ajustes de brilho e contraste, criando dez novas imagens para cada imagem original. Essa técnica aumentou a capacidade do modelo de generalizar padrões e reconhecer variações contextuais, ao mesmo tempo em que fortaleceu sua robustez contra problemas de *overfitting*. Além disso, a padronização de tamanho facilitou a aplicação dessas transformações de maneira homogênea, garantindo que o modelo aprendesse padrões relevantes para a segmentação e identificação dos animais, mesmo em variações de pose, iluminação e cenário.

No segundo conjunto de dados, com imagens capturadas em condições reais, os cenários e ângulos foram mais restritos, tornando o pré-processamento ainda mais crucial para adaptar o modelo ao ambiente de aplicação. Esse tratamento mais específico das classes e o controle rigoroso dos cenários aprimoraram a precisão na segmentação e identificação dos animais, principalmente em condições complexas e dinâmicas. Como resultado, essas operações de pré-processamento fortaleceram significativamente a capacidade de generalização do modelo, proporcionando um desempenho robusto e confiável para segmentação de objetos.

3.4. GERAÇÃO DO MODELO

O modelo treinado neste trabalho foi implementado em Python, utilizando as bibliotecas OpenCV², Numpy³, YOLO⁴, DeepSort⁵, hashlib⁶ e JSON⁷. O ambiente de desenvolvimento escolhido foi o Google Colab, que permite a criação de códigos Python diretamente no navegador, sem a necessidade de configurações complexas. Para o treinamento do modelo, foi utilizada uma máquina virtual A100 com GPU dedicada de alto desempenho, permitindo que o treinamento fosse realizado de maneira rápida e eficaz.

O primeiro modelo foi treinado ao longo de 200 épocas utilizando um modelo pré-treinado disponibilizado pelo YOLOv8, especificamente o YOLOv8x-seg, a versão mais robusta da série. Essa escolha permitiu alcançar uma segmentação aceitável nas imagens de teste. Durante o treinamento, várias métricas foram monitoradas para avaliar os modelo, incluindo *precision* (precisão), *recall* (revocação) e mAP50 (média de precisão média em 50%).

No entanto, identificou-se a necessidade de desenvolver um novo modelo, considerando condições de treinamento mais específicas e controladas. Para isso, adotou-se um modelo pré-treinado YOLOv8n-seg, com uma arquitetura de menor complexidade e menos camadas. Esse novo modelo foi treinado por 100 épocas, com uma paciência de até 30 épocas sem variação no desempenho, permitindo interromper o treinamento quando os resultados se estabilizavam. A redução na quantidade de camadas, aliada a um conjunto de dados mais restrito, resultou em um modelo mais leve, com métricas superiores ao modelo anterior, adaptado a cenários controlados e com precisão significativamente melhor. Abaixo estão as fórmulas das principais métricas utilizadas para avaliação do desempenho:

1. **Precisão (*Precision*):** A precisão é uma métrica que indica a proporção de previsões corretas feitas pelo modelo em relação ao total de previsões positivas (verdadeiras e falsas) que ele fez. Em outras palavras, é a fração de verdadeiros positivos entre todas as instâncias previstas como positivas pelo modelo. A fórmula é:

$$Precision = \frac{true_{positive}}{true_{positive} + false_{positive}} \quad (1)$$

onde:

- *true_{positive}* representa o número de previsões verdadeiras e positivas, ou seja, instâncias que foram corretamente identificadas pelo modelo como positivas.
- *false_{positive}* representa o número de previsões incorretas onde o modelo identificou uma instância negativa como positiva.

2. **Revocação (*Recall*):** A revocação, ou sensibilidade, mede a capacidade do modelo de identificar todas as instâncias verdadeiramente positivas em um conjunto

²<<https://opencv.org/>>

³<<https://numpy.org/>>

⁴<<https://docs.ultralytics.com/>>

⁵<<https://docs.ultralytics.com/>>

⁶<<https://docs.python.org/3/library/hashlib.html>>

⁷<<https://www.json.org/json-en.html>>

de dados. Em outras palavras, calcula a fração de verdadeiros positivos em relação ao total de instâncias que realmente pertencem à classe positiva. A fórmula é:

$$Recall = \frac{true_{positive}}{true_{positive} + false_{negative}} \quad (2)$$

onde:

- $true_{positive}$ representa o número de previsões verdadeiras e positivas.
- $false_{negative}$ representa o número de instâncias que o modelo deixou de identificar corretamente como positivas, ou seja, instâncias que são positivas mas que foram classificadas como negativas.

3. Média de Precisão Média (mAP@50): A métrica de média de precisão média em uma sobreposição de 50% (mAP@50) avalia a precisão do modelo considerando a área sob a curva de precisão e revocação. Aqui, mAP@50 corresponde à média de precisão calculada considerando uma interseção sobre a união (IoU) de pelo menos 50

$$mAP@50 = \frac{\sum_{i=1}^I \int_0^1 precision_i(recall) dRecall}{I} \quad (3)$$

onde:

- I é o número total de classes no conjunto de dados.
- $precision_i$ é a precisão da i -ésima classe em função da revocação.
- $recall$ varia de 0 a 1, e o valor de $mAP@50$ é obtido integrando a precisão em relação à revocação ao longo do intervalo de 0 a 1 para cada classe, seguido pela média de todos os valores de precisão média.

Essas fórmulas são fundamentais para avaliar o desempenho de modelos de detecção e segmentação de objetos, fornecendo uma visão sobre a precisão e a capacidade de generalização do modelo em relação à identificação correta de instâncias e classes nos dados de teste.

Através dessas métricas foi possível medir a eficácia do modelo na identificação de vacas nas imagens. Antes de iniciar o desenvolvimento do modelo atual, diversos treinamentos foram realizados com o objetivo de refinar a segmentação e a precisão na identificação dos objetos. No primeiro modelo, utilizando um conjunto de dados mais abrangente, a segmentação alcançou uma média de 93% de precisão, conforme ilustrado na Figura 8. Esse modelo inicial foi eficaz, mas apresentava limitações em condições mais desafiadoras e variadas, especialmente em cenários que exigiam uma segmentação mais detalhada e precisa dos objetos.

Diante desses desafios, um novo treinamento foi realizado com um conjunto de dados reformulado e mais restrito. Esse conjunto incorporou imagens capturadas em condições mais controladas, aproximando-se mais dos cenários reais de aplicação. O modelo foi ajustado para capturar características específicas e segmentar o objeto com maior precisão. Como resultado, o novo modelo apresentou métricas significativamente aprimoradas, atingindo uma precisão média de 99% no treinamento, o que

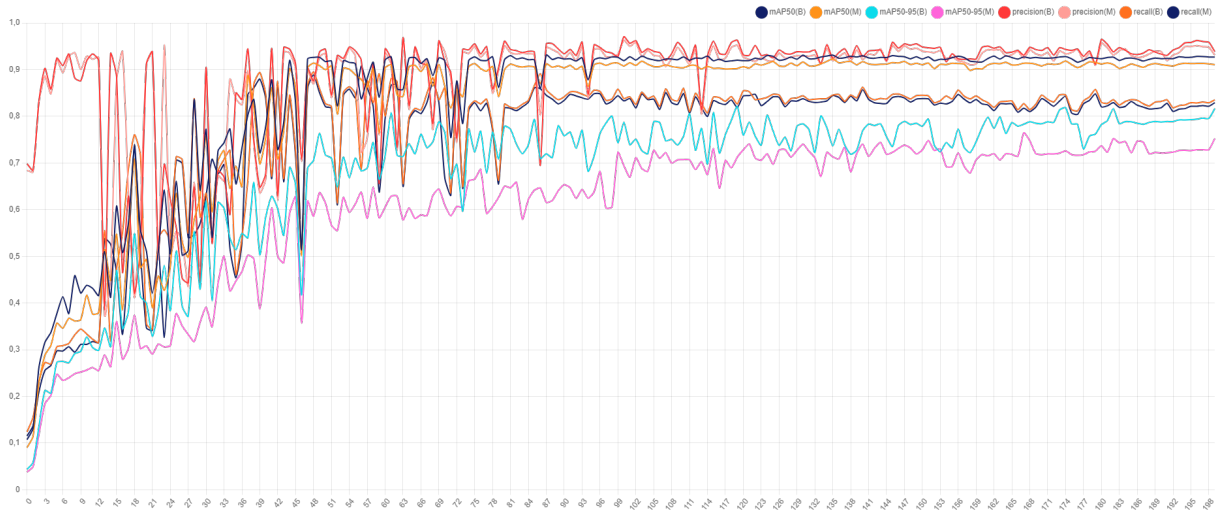


Figura 8 - Treinamento do Modelo.




Figura 9 - Treinamento do Modelo Novo.

reflete a eficácia do modelo em condições de uso prático, conforme mostrado na Figura 9

A Figura 10 e a Figura 11 representam as perdas durante o treinamento de um modelo de detecção de objetos, possivelmente usando o algoritmo YOLOv8. Serão explicadas cada uma das perdas:

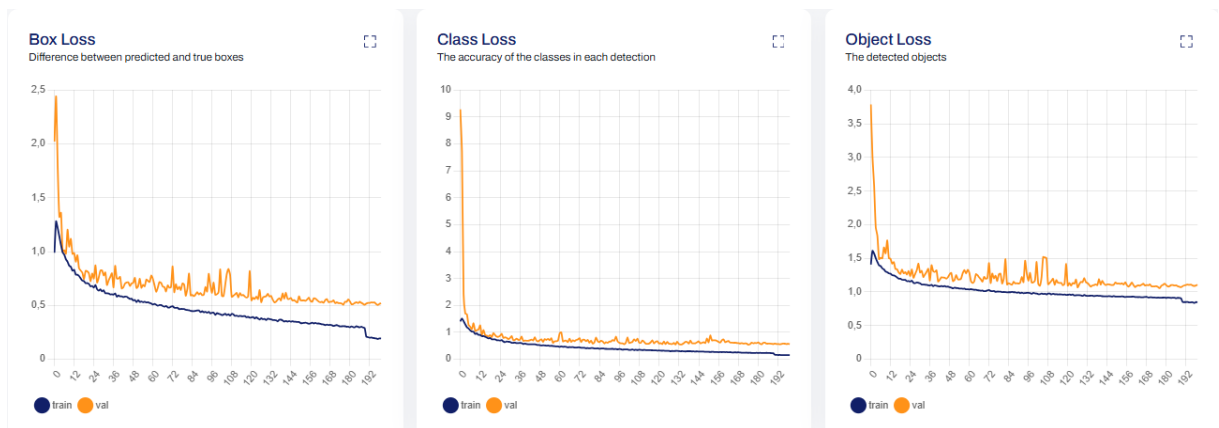


Figura 10 - Box Perdas.



Figura 11 - Box Perdas Novo.

A **Perda de Caixa (Box Loss)** mede o quão bem o modelo está ajustando as caixas delimitadoras (*bounding boxes*) ao redor dos objetos detectados. Uma baixa perda de caixa indica que as caixas estão se ajustando bem aos objetos reais nas imagens. A **Perda de Classe (Class Loss)** avalia a precisão do modelo na classificação dos objetos detectados. Ela mede o quão bem o modelo está atribuindo as classes corretas aos objetos. Uma baixa perda de classe indica que o modelo está acertando as categorias dos objetos. A **Perda de Objeto (Object Loss)** combina as duas anteriores e representa a eficácia geral do modelo em detectar e classificar objetos. Uma baixa perda de objeto significa que o modelo está fazendo um bom trabalho em ambos os aspectos.

Essas figuras ilustram a evolução das perdas ao longo das épocas de treinamento. Em uma breve comparação entre os modelos, é possível observar que a escala de perda dos objetos apresenta diferenças significativas: o primeiro modelo inicia com perdas mais elevadas, enquanto o novo modelo, desde o início do treinamento, apresenta valores mais baixos, o que contribui para uma eficiência superior na aplicação prática dos modelos.

No início, as perdas são mais altas, mas conforme o treinamento avança, elas diminuem gradativamente. O objetivo é reduzir todas as perdas para alcançar um modelo preciso e confiável na detecção de objetos. As Figuras 10 e 11 ilustram a evolução das perdas durante o processo de validação, destacando a melhoria contínua do modelo ao longo do treinamento.

3.5. DETECÇÃO E SEGMENTAÇÃO DE GADO USANDO REDE YOLOV8

Nesta seção, abordaremos o processo de detecção e segmentação de gado utilizando dois modelos treinados distintos, discutindo as técnicas aplicadas e os resultados obtidos em ambientes reais.

O primeiro modelo, baseado na arquitetura YOLOv8 com redes neurais convolucionais (CNNs), foi projetado para realizar a detecção e segmentação inicial dos animais nas imagens. Este modelo foi treinado para identificar e delimitar com precisão as áreas de interesse dos animais, conforme ilustrado na Figura 12. Os experimentos foram realizados em diversos cenários, com variações em iluminação, ângulos e outras condições ambientais, o que proporcionou uma ampla gama de dados para

análise. Esse modelo inicial apresentou resultados satisfatórios em condições controladas, mas revelou algumas limitações em ambientes menos estruturados.

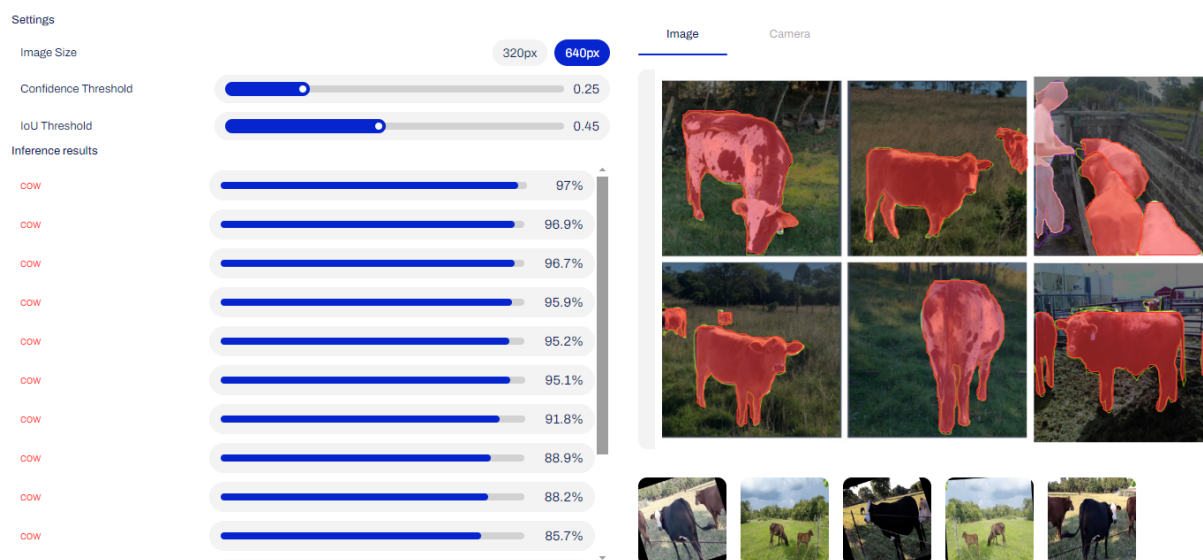


Figura 12 - Detecção e Segmentação Modelo Versao 1.

Em resposta a essas limitações, desenvolvemos um segundo modelo com uma arquitetura otimizada e menos complexa, porém mais especializada para o contexto de segmentação de gado em ambientes reais. Esse novo modelo foi treinado com um conjunto de dados mais restrito e cuidadosamente selecionado, permitindo uma segmentação mais precisa dos animais, mesmo em cenários desafiadores. A Figura 13 demonstra a eficácia desse segundo modelo, que se destacou por uma taxa de segmentação superior, especialmente em ambientes não controlados. Essa evolução permitiu uma maior confiabilidade na detecção e na extração de parâmetros anatômicos.

Os resultados mostram que o segundo modelo apresenta uma melhor performance, especialmente em ambientes com variabilidade, enquanto o primeiro modelo oferece uma boa base para detecção em cenários mais controlados.

3.6. PROCESSO DE EXTRAÇÃO DE PARÂMETROS DE TAMANHO CORPORAL

Para estimar o peso do gado utilizando a segmentação de imagens, o algoritmo segue uma série de etapas bem definidas. O processo baseia-se na medição das características físicas do animal, como comprimento e largura, a partir de imagens segmentadas. Essas medidas são então convertidas em estimativas de peso utilizando uma fórmula ajustada, que reflete a correlação entre essas dimensões e o peso do animal.

3.6.1. ETAPAS DO PROCESSO

O processo de pesagem de gado baseado em tecnologia de visão computacional e aprendizado de máquina começa com a segmentação do objeto, onde a identificação precisa do animal nas imagens ou vídeos coletados é realizada. Essa etapa é essencial para extrair as informações necessárias sobre a forma, contornos e outras características do gado. A segmentação cria uma representação visual clara do

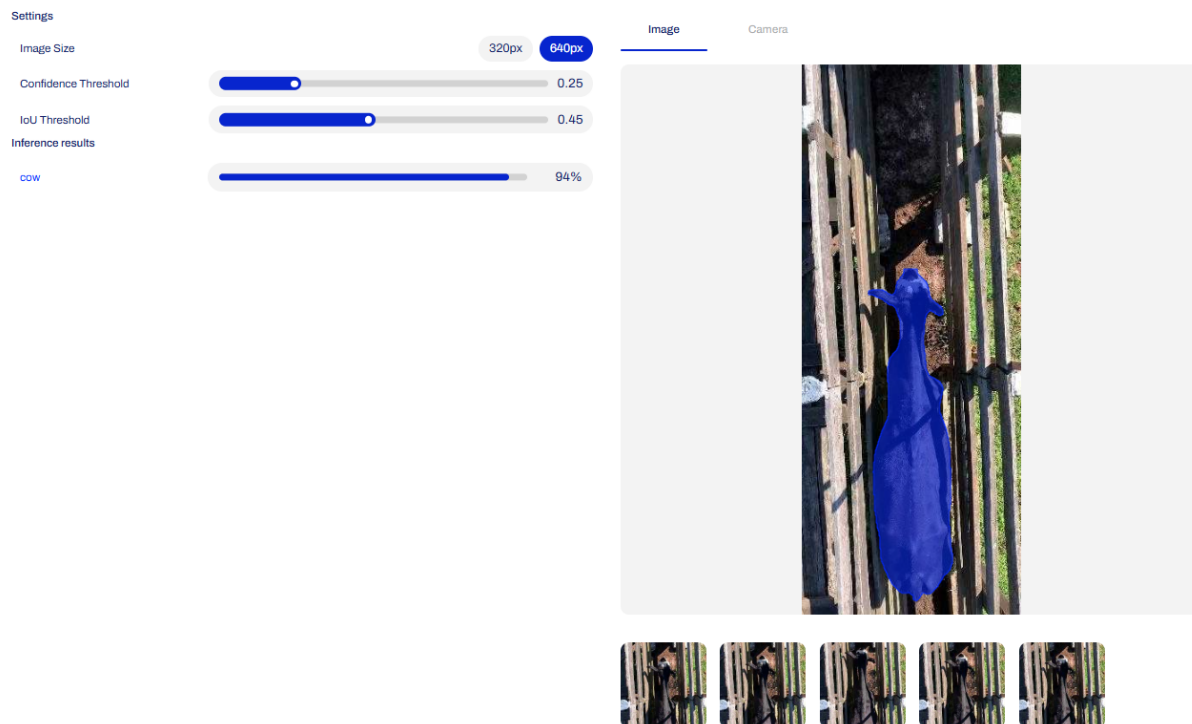


Figura 13 - Detecção e Segmentação Versao 2.

animal, identificando suas bordas e delimitando as áreas de interesse dentro da imagem. Com esses dados, é possível acessar as coordenadas dos pontos específicos que compõem a figura do animal, fornecendo uma base para medições posteriores. A segmentação do objeto é, portanto, a primeira etapa de um processo complexo que envolve a coleta de dados visuais em tempo real.

Após a segmentação, é realizada a determinação da distância entre pontos específicos extraídos da segmentação, como o comprimento entre o pescoço e o quadril, ou outras medições relevantes para a análise do gado. A distância entre esses pontos é calculada utilizando a fórmula da distância euclidiana, que considera a diferença de coordenadas nos eixos X e Y :

$$Tamanho(px) = \sqrt{(x_1 - x_2)^2 + (y_1 - y_2)^2} \quad (4)$$

Onde:

- (x_1, y_1) e (x_2, y_2) são as coordenadas dos dois pontos extraídos da segmentação da imagem.
- A fórmula calcula a distância reta entre esses dois pontos no plano 2D, permitindo assim determinar as dimensões do animal de forma precisa.

Em seguida, é feita a conversão das dimensões dos objetos detectados (como o comprimento ou a largura do corpo do gado) de pixels para unidades de medida reais, como centímetros. Essa conversão é feita utilizando a seguinte fórmula:

$$Tamanho (cm) = \frac{Tamanho (px)}{PPI} \times 2.54 \quad (5)$$

Onde:

- *Tamanho (px)* representa a medida obtida em pixels da segmentação.
- *PPI* é a resolução da imagem em pontos por polegada (*pixels per inch*).
- O fator 2.54 converte a medida de polegadas para centímetros.

Esse cálculo fornece a medida exata entre os pontos de interesse no espaço 2D da imagem. Com a conversão para centímetros, é possível determinar com precisão as dimensões do animal. O próximo passo no processo seria a utilização dessas medidas para estimar o peso do gado, utilizando modelos preditivos baseados em aprendizado de máquina ou análise estatística, que associam as dimensões físicas do animal ao seu peso corporal. Esse processo não invasivo e altamente preciso não só melhora o bem-estar dos animais ao evitar o estresse causado pela pesagem tradicional, mas também otimiza os processos logísticos nas fazendas, tornando o manejo pecuário mais eficiente e eficaz.

3.7. MODELO DE REGRESSÃO DE PARÂMETROS REAIS DE PESO CORPORAL E PESO CORPORAL MEDIDOS

O desenvolvimento de um modelo de regressão para correlacionar parâmetros reais de peso corporal com pesos corporais medidos visa aprimorar a precisão das estimativas de peso em gado, utilizando tecnologias avançadas de visão computacional e aprendizado de máquina. Este processo compreende diversas etapas: captura de imagens, extração de medidas corporais, desenvolvimento e validação de modelos de regressão, e comparação das estimativas com os pesos obtidos em balanças tradicionais.

A Figura 14 é uma representação ilustrada dos possíveis pontos que podemos extrair para a remoção das métricas para a predição do peso. Utilizamos como base larguras de quadril, comprimento total, largura de pescoço, largura de costelas, entre outras medidas.

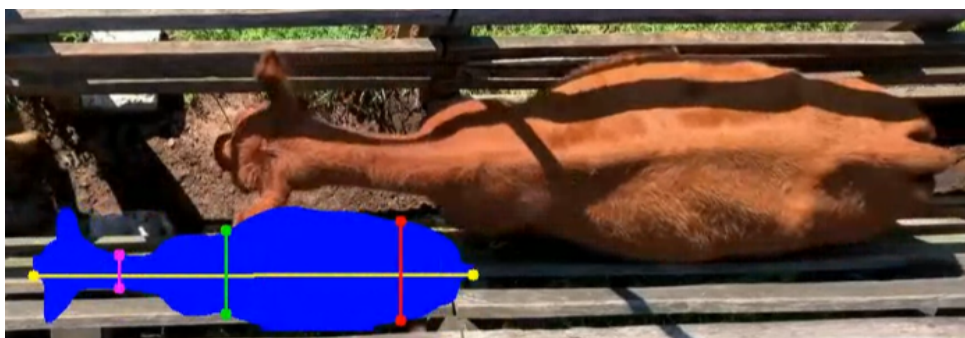


Figura 14 - Exemplo Metricas Gado.

Utilizamos a biblioteca OpenCV para o pré-processamento das imagens, corrigindo distorções e normalizando escalas para garantir consistência. Calculamos medidas de comprimento (do focinho à base da cauda) e largura nos pontos estipulados dos animais, atribuindo coordenadas específicas para assegurar precisão na extração das medidas.

A Figura 15 ilustra a formulação de um sistema linear, no qual as medições físicas do animal (x_1, x_2, x_3, x_4) são relacionadas aos pesos reais conhecidos (y_1, y_2, y_3, y_4). O objetivo deste sistema é determinar os coeficientes desconhecidos (a, b, c, d), que são os parâmetros que ajustam as medições físicas às estimativas de peso do animal. A resolução matricial do sistema permite calcular esses coeficientes de maneira eficiente e precisa, oferecendo uma maneira robusta de modelar a relação entre as variáveis de entrada e o peso.

$$\begin{array}{c}
 \text{Variável Desejada} \leftarrow \\
 \begin{bmatrix}
 x_1^{(1)} & x_2^{(1)} & x_3^{(1)} & x_4^{(1)} \\
 x_1^{(2)} & x_2^{(2)} & x_3^{(2)} & x_4^{(2)} \\
 x_1^{(3)} & x_2^{(3)} & x_3^{(3)} & x_4^{(3)} \\
 x_1^{(4)} & x_2^{(4)} & x_3^{(4)} & x_4^{(4)}
 \end{bmatrix}
 \begin{bmatrix}
 a \\
 b \\
 c \\
 d
 \end{bmatrix}
 =
 \begin{bmatrix}
 y_1 \\
 y_2 \\
 y_3 \\
 y_4
 \end{bmatrix} \\
 \begin{array}{c}
 \leftarrow \\
 \text{Peso}
 \end{array}
 \end{array}$$

Figura 15 - Representação matricial do sistema linear.

Na Figura 16, são apresentados os cálculos dos termos $x^{(i)}$ dentro da matriz. Cada termo $x_1^{(1)}$, por exemplo, é obtido pela soma das medições x_1 realizadas para diferentes animais, seguindo um padrão específico para cada variável. Isso garante que todas as medições realizadas durante os experimentos sejam corretamente incorporadas ao sistema. A representação dos termos de forma detalhada permite uma visualização clara do processo de transformação das medições em valores que contribuirão para o cálculo final do peso.

$$\begin{array}{c}
 x_1^{(1)} = x_1 + x_1 + x_1 \\
 \begin{array}{ccc}
 \uparrow & \uparrow & \uparrow \\
 \text{Gado1} & \text{Gado2} & \text{Gado3} \\
 \downarrow & \downarrow & \downarrow
 \end{array} \\
 x_2^{(1)} = x_2 + x_2 + x_2
 \end{array}
 \left|
 \begin{array}{c}
 x_1^{(2)} = x_1 + x_1 + x_1 \\
 \begin{array}{ccc}
 \uparrow & \uparrow & \uparrow \\
 \text{Gado1} & \text{Gado2} & \text{Gado3} \\
 \downarrow & \downarrow & \downarrow
 \end{array} \\
 x_2^{(2)} = x_2 + x_2 + x_2
 \end{array}$$

Figura 16 - Cálculo dos termos $x^{(i)}$ na matriz.

A Figura 17 detalha como os pesos y_i são calculados a partir das contribuições individuais de cada animal. Por exemplo, o peso y_1 é a soma das medições de peso de diferentes instâncias do mesmo animal $y_1^{(1)}, y_1^{(2)}$ e $y_1^{(3)}$, o que reflete o processo de validação e verificação das medições. Esse processo de agregação dos dados garante uma estimativa mais precisa e confiável do peso do animal.

A Equação 6 formaliza a relação entre as medições físicas do animal e o seu peso estimado.

$$y_1 = y_1^{(1)} + y_1^{(2)} + y_1^{(3)}$$

↑
Peso
Gado1

↑
Peso
Gado2

↑
Peso
Gado3

Figura 17 - Pesos y_i verificados na balança.

$$\text{Peso (kg)} = a \cdot x_1 + b \cdot x_2 + c \cdot x_3 + d \cdot x_4 \quad (6)$$

onde:

- x_1 : comprimento do animal,
- x_2 : largura do pescoço,
- x_3 : largura do tórax,
- x_4 : largura do quadril,
- a, b, c, d : coeficientes determinados experimentalmente.

A equação descreve como o peso do animal é calculado como uma combinação ponderada de quatro variáveis físicas (comprimento, largura do pescoço, largura do tórax e largura do quadril), com coeficientes (a, b, c, d) que são determinados experimentalmente. Cada um desses coeficientes representa a importância relativa de cada característica física na estimativa do peso do animal. Ao ajustar esses coeficientes por meio de dados experimentais, o modelo pode fornecer estimativas de peso mais precisas e aplicáveis em diferentes cenários.

Para desenvolver o modelo, foram coletados dados históricos de medidas corporais e pesos reais obtidos por balanças tradicionais. O modelo de regressão foi treinado com esses dados, ajustando a equação para minimizar o erro entre os pesos preditos e os reais, utilizando métricas como o Erro Médio Absoluto (MAE) e a Raiz do Erro Quadrático Médio (RMSE):

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (7)$$

onde:

- n é o número total de observações.
- y_i são os valores reais.
- \hat{y}_i são os valores preditos pelo modelo.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (8)$$

onde:

- n é o número total de observações.
- y_i são os valores reais.
- \hat{y}_i são os valores preditos pelo modelo.

Após o treinamento, o modelo foi validado e refinado com dados adicionais, possibilitando a aplicação em tempo real. Com o sistema implementado, a pesagem automatizada promove maior precisão e eficiência, contribuindo para o bem-estar animal e a competitividade do setor pecuário.

4. RESULTADOS

Nesta seção, são apresentados os resultados detalhados da prova de conceito do sistema de pesagem automatizada de gado. A prova de conceito foi conduzida utilizando dois modelos baseados na arquitetura YOLOv8, aplicados a um conjunto de dados representativo de cenários reais. O objetivo principal foi avaliar a capacidade do sistema em detectar e segmentar o gado sob diferentes condições, além de analisar as métricas de precisão, revocação e a média de precisão média (mAP@50) para validar a eficácia dos modelos.

4.1. AVALIAÇÃO DOS MODELOS TREINADOS

Nesta seção, são apresentados os resultados detalhados da avaliação dos modelos treinados em ambiente de teste. O objetivo desta análise é comparar o desempenho dos diferentes modelos desenvolvidos, destacando as variações em termos de precisão, robustez e eficiência em diferentes cenários de aplicação. Além disso, exploramos as melhorias obtidas com as alterações implementadas em cada modelo e analisamos o impacto dessas mudanças nas métricas de desempenho, como precisão média (mAP@50), revocação e taxa de falsos positivos.

Para cada modelo, foram avaliados parâmetros específicos relacionados à capacidade de detectar e segmentar corretamente o gado em condições variadas, incluindo mudanças nas condições de iluminação, presença de múltiplos objetos no fundo, e diferentes ângulos e posições dos animais. Essas condições foram projetadas para simular cenários reais encontrados em ambientes de criação, permitindo uma avaliação abrangente e prática da eficácia dos modelos.

A análise comparativa foca também nas diferenças arquiteturais entre os modelos, especialmente no que diz respeito ao número de camadas, métodos de regularização e estratégias de parada antecipada. Essas modificações visaram otimizar o equilíbrio entre precisão e eficiência computacional, garantindo que o modelo final seja suficientemente preciso para o ambiente de criação, ao mesmo tempo que se mantém leve o suficiente para ser implementado em dispositivos de processamento limitados.

Por fim, são discutidos os principais desafios enfrentados durante o treinamento e teste dos modelos, incluindo as limitações observadas e as oportunidades de melhorias para futuras iterações. A análise apresentada aqui oferece uma visão abrangente dos pontos fortes e fracos de cada modelo, permitindo identificar o modelo mais adequado para a implementação no sistema de pesagem de gado.

4.1.1. PRIMEIRO MODELO – TREINAMENTO COM 200 ÉPOCAS

O primeiro modelo foi submetido a um treinamento intensivo, totalizando 200 épocas, com uma tolerância de até 100 épocas consecutivas sem melhorias, conforme ilustrado na Figura 8. O conjunto de dados utilizado no treinamento foi cuidadosamente diversificado, incluindo imagens de gado em diferentes poses, tamanhos, e sob variadas condições de iluminação, proporcionando uma amostra representativa dos cenários encontrados em ambientes reais de criação, conforme ilustrado na Figura 12.

Com essa configuração de treinamento, o modelo atingiu uma precisão média de 93%, apresentando bom desempenho em condições controladas onde havia pouca interferência no fundo das imagens e iluminação uniforme. Esses cenários permitiram que o modelo se concentrasse na segmentação e detecção precisa dos contornos do gado, obtendo alta acurácia em imagens relativamente simplificadas. Contudo, em situações mais complexas e desafiadoras, o modelo mostrou algumas limitações significativas. Cenários com iluminação irregular, presença de múltiplos objetos de fundo, ângulos divergentes de 90 graus e imagens em que partes do animal estavam fora do campo de visão impactaram negativamente o desempenho do modelo.

Além disso, ao analisar a segmentação em vídeos capturados predominantemente em um ângulo de 90 graus, foram observadas anomalias que resultaram em distorções no formato do objeto segmentado. Esse posicionamento causava deformações nos contornos do gado, dificultando a extração precisa dos parâmetros desejados. Essas condições adversas impactaram a taxa de mAP@50, especialmente nos testes em vídeo, onde as variações dinâmicas dos cenários aumentaram a complexidade da tarefa de segmentação, comprometendo a consistência nas detecções. Esse comportamento indicou a necessidade de ajustes adicionais no modelo para torná-lo mais robusto em situações de campo com variabilidade elevada.

4.1.2. SEGUNDO MODELO – TREINAMENTO COM 100 ÉPOCAS E PARADA ANTECIPADA

Para superar as limitações observadas no primeiro modelo, desenvolvemos um segundo modelo com uma arquitetura otimizada e mais leve, visando aprimorar o desempenho em cenários variados e complexos. Esse modelo foi configurado para um treinamento de 100 épocas, com uma tolerância de 30 épocas sem melhorias, o que permitiu encerrar o processo de treinamento de forma antecipada, evitando sobreajustes e reduzindo o tempo computacional necessário.

Além das melhorias na arquitetura, uma das principais correções foi a adaptação do modelo e do dataset para mitigar as distorções observadas anteriormente em ângulos de 90 graus. Com ajustes específicos nos parâmetros e uma reestruturação dos dados de treinamento, o novo modelo conseguiu segmentar o animal com maior precisão, mesmo em vídeos capturados predominantemente nesse ângulo. Esse refinamento na modelagem possibilitou uma melhor adaptação a cenários reais de criação de gado, onde ângulos fixos e iluminação variável são comuns.

A configuração aprimorada proporcionou um desempenho significativamente superior, alcançando uma precisão média de até 99% no mAP@50. A arquitetura leve e os parâmetros ajustados tornaram o modelo mais adaptável a condições reais, onde elementos de fundo e posições dos animais mudam constantemente. Essa eficiência adaptativa faz com que o segundo modelo seja altamente adequado para implementação prática, oferecendo alta precisão sem comprometer a velocidade de processamento.

Os resultados de segmentação desse modelo em diversos cenários são ilustrados na Figura 13, mostrando a capacidade do modelo de identificar e segmentar o gado, mesmo em condições de iluminação desfavorável e com objetos de distração no fundo. Este segundo modelo representa, assim, um avanço notável em relação ao primeiro, equilibrando precisão e eficiência, e oferece um desempenho superior para aplicações de pesagem.

4.2. OBSERVAÇÃO E SELEÇÃO DE QUADROS PARA EXTRAÇÃO DE PARÂMETROS

Nos testes realizados com o segundo modelo, a configuração da câmera foi um elemento essencial para alcançar resultados mais precisos. Posicionada a uma altura de 3,5 metros e ajustada em um ângulo fixo de 90 graus em relação ao solo, essa configuração minimizou interferências externas durante a extração dos parâmetros. Essa abordagem corrigiu as limitações do primeiro modelo, que utilizava imagens laterais e variadas, frequentemente confundindo o modelo e introduzindo distorções na segmentação e extração dos parâmetros.

No segundo modelo, a base de dados foi reformulada com maior especificidade e consistência, permitindo que as características das imagens fossem ajustadas para facilitar a projeção e análise dos dados. Essa adaptação não apenas melhorou a segmentação, mas também garantiu que o modelo fosse mais robusto em condições reais de aplicação.

Durante os testes, foi possível identificar um padrão nos quadros que melhor representavam as características necessárias para o cálculo do peso. A análise contínua dos frames permitiu selecionar um subconjunto de imagens otimizadas, que foram posteriormente normalizadas para assegurar uma maior consistência e precisão na predição de peso.

Os quadros selecionados apresentaram as seguintes características principais:

- **Iluminação Consistente:** Quadros com iluminação uniforme resultaram em segmentações mais precisas, eliminando áreas de sombra ou brilho excessivo que poderiam comprometer a análise.
- **Visão Superior Estável:** A visão superior, proporcionada pela configuração da câmera, revelou-se ideal para a extração detalhada de parâmetros como o perímetro torácico e o comprimento do corpo, que são fundamentais para a predição de peso.
- **Fundo Simples e Neutro:** Imagens capturadas com fundos homogêneos apresentaram menor interferência, permitindo que o modelo se concentrasse na morfologia do animal sem distrações.

Essa abordagem de seleção criteriosa e normalização dos quadros contribuiu significativamente para a consistência e precisão dos dados extraídos. Como resultado, as métricas do modelo foram aprimoradas, reforçando a eficácia da segmentação e predição de peso em ambientes reais de criação de gado.

4.3. MÉTRICAS COMPARATIVAS E DESEMPENHO DOS MODELOS

A Tabela 2 apresenta uma comparação detalhada das métricas obtidas pelos dois modelos:

Tabela 2 - Comparação das Métricas dos Modelos de Segmentação.

Métrica	Primeiro Modelo (200 Épocas)	Segundo Modelo (100 Épocas)	Varição (%)
Precisão (%)	0.959	0.997	+ 3.950 %
Recall (%)	0.829	0.993	+19.770 %
mAP@50 (%)	0.927	0.995	+ 7.330 %

Esses resultados demonstram que o segundo modelo, treinado por 100 épocas, é significativamente mais eficiente e robusto, alcançando maior precisão e recall em comparação ao primeiro modelo, que foi treinado por 200 épocas. Além disso, o segundo modelo apresenta um desempenho superior em termos de mAP@50, com uma melhoria de 7.33%. A simplificação da arquitetura, por meio da redução de camadas, aliada ao uso de dados mais restritos, resultou em um sistema com menor custo computacional, enquanto mantém um alto desempenho, o que o torna mais adequado para ambientes reais.

Esses avanços comprovam a viabilidade da abordagem de pesagem automatizada de gado baseada em visão computacional. O segundo modelo, com a arquitetura otimizada e menos épocas de treinamento, mostrou-se altamente eficaz para aplicações no setor pecuário, garantindo detecção e segmentação precisas em cenários variados. Essa solução é promissora para a indústria pecuária, proporcionando melhorias em eficiência produtiva, precisão na pesagem e contribuindo para o bem-estar animal.

4.4. ANÁLISE DE PESOS E MÉTRICAS EM AMBIENTE DE PRODUÇÃO

A validação de modelos de estimativa de peso para bovinos em cenários reais é fundamental para garantir a precisão e a eficiência de sua aplicação em ambientes de produção. Através dessa análise, é possível avaliar a eficácia do modelo em condições práticas, identificando pontos de melhoria para aprimorar os resultados e atender às demandas do setor agropecuário.

Na Tabela 3, são apresentados os dados obtidos para sete animais. A análise inclui o peso aferido em balança (referência), o peso estimado pelo modelo de inteligência artificial e as respectivas métricas: confiança do modelo, erro percentual, erro absoluto médio (MAE) e raiz do erro quadrático médio (RMSE). Essas métricas são úteis para determinar o desempenho geral do modelo em relação ao padrão de referência.

Na Tabela 3, a primeira coluna lista os animais avaliados. A segunda coluna exibe a confiança do modelo em porcentagem, representando o grau de precisão na

Tabela 3 - Análise de Pesos e Métricas em Ambiente de Produção.

Animal	Confiança do Modelo (%)	Peso na Balança (kg)	Peso pelo Modelo (kg)	Erro (%)	MAE	RMSE
1	0.97	387	386.60	0.10	0.40	0.40
2	0.96	321	328.70	2.40	7.70	7.70
3	0.97	401	395.63	1.34	5.37	5.37
4	0.97	403	401.05	0.48	1.95	1.95
5	0.97	426	416.07	2.33	9.93	9.93
6	0.97	424	424.37	0.09	0.37	0.37
7	0.97	403	397.08	1.47	5.92	5.92
Média	-	-	-	1.17	4.95	5.24

identificação de características corporais dos bovinos. A terceira coluna apresenta o peso real aferido na balança, utilizado como referência. A quarta coluna mostra o peso estimado pelo modelo com base em métricas extraídas das imagens processadas. A quinta coluna detalha o erro percentual, calculado como a diferença relativa entre os pesos real e estimado. Por fim, as colunas *MAE* (erro absoluto médio) e *RMSE* (raiz do erro quadrático médio) fornecem indicadores complementares da qualidade do modelo em geral.

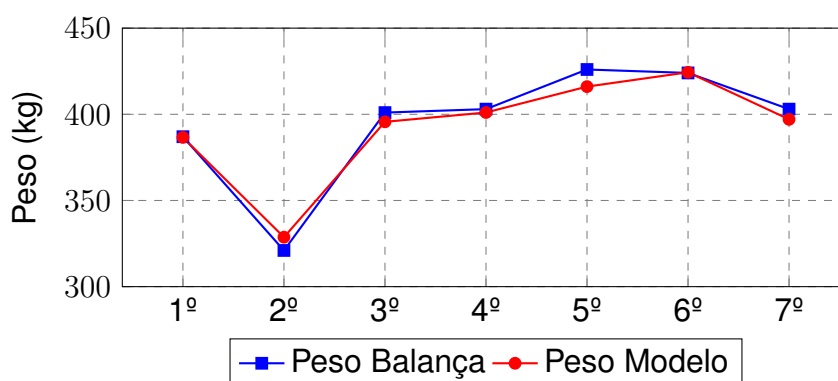


Figura 18 - Evolução do modelo com base nos pesos da balança e pesos do modelo.

A Figura 18 complementa a análise ao comparar visualmente os pesos aferidos na balança com os estimados pelo modelo. Observa-se que, na maioria dos casos, o modelo apresenta alta precisão, com erros percentuais geralmente abaixo de 5%. Essa performance é satisfatória para aplicações práticas, como a gestão de peso e a saúde de rebanhos.

Apesar da precisão geral, algumas discrepâncias, como a observada para o animal 2 e o 5, indicam a necessidade de ajustes no modelo. Tais ajustes podem envolver a calibração de parâmetros ou a inclusão de novas amostras no treinamento para melhorar o desempenho em cenários com características atípicas. Esses resultados reforçam a importância de validações contínuas e de um monitoramento criterioso para assegurar a confiabilidade e robustez do sistema em longo prazo.

5. CONSIDERAÇÕES FINAIS

Este estudo apresentou uma análise abrangente sobre a modernização da pesagem de gado no Brasil, destacando o uso de tecnologias avançadas como YOLOv8 e OpenCV. O modelo proposto, que utiliza visão computacional e aprendizado de má-

quina, demonstrou seu grande potencial para transformar a maneira como os pecuaristas medem o peso do gado, trazendo benefícios significativos para a eficiência operacional, redução de custos logísticos e, especialmente, para o bem-estar animal. A substituição dos métodos tradicionais por abordagens automatizadas pode não apenas melhorar a precisão das medições, mas também contribuir para a sustentabilidade e competitividade do setor agropecuário nacional.

Os resultados obtidos indicam que a combinação das tecnologias YOLOv8 e OpenCV oferece uma solução robusta para a detecção e predição do peso corporal do gado de forma não invasiva, eficiente e em tempo real. A precisão do modelo demonstrou sua capacidade de otimizar o monitoramento do peso, proporcionando um gerenciamento mais ágil e preciso, além de possibilitar uma resposta mais rápida às demandas do mercado. Esses avanços também refletem-se positivamente na saúde financeira dos produtores e na qualidade da carne produzida, aspectos essenciais para o crescimento contínuo do setor.

Contudo, é importante reconhecer os limites deste estudo. Embora os resultados tenham sido promissores, o modelo ainda enfrenta desafios, como a necessidade de ajustes para animais com características corporais atípicas ou em cenários específicos onde o erro estimado possa ser maior. Além disso, a implementação de sistemas automatizados em grande escala em ambientes de produção exige adaptações para diferentes condições operacionais, o que pode demandar investimentos adicionais.

A pesquisa apresentada abre novas possibilidades para trabalhos futuros voltados ao aprimoramento da estimativa de peso e do monitoramento do gado. Testes com conjuntos de dados variados são fundamentais para avaliar a robustez e a capacidade de generalização do modelo, além de ajudar a mitigar potenciais problemas de overfitting. Refinar o cálculo da pesagem, por meio da análise de correlações entre características morfológicas e métricas de peso, pode proporcionar ganhos consideráveis em termos de precisão.

Além disso, a seleção automática do frame mais representativo para análise e a aplicação de técnicas estatísticas, como a regressão linear, têm grande potencial para otimizar os resultados. Por fim, a validação do modelo em ambientes reais é crucial para consolidar sua aplicabilidade no setor pecuário e expandir sua utilização prática.

Em suma, a conclusão deste estudo reforça a importância da inovação no setor agropecuário. As tecnologias aplicadas têm o potencial de transformar a forma como o gado é monitorado, trazendo benefícios econômicos e operacionais, além de melhorar a qualidade do produto final. À medida que essas tecnologias continuam a evoluir, espera-se que sua adoção se torne cada vez mais ampla, estabelecendo um novo padrão de eficiência e sustentabilidade para o mercado pecuário nacional.

REFERÊNCIAS

AGHDAM, H. H.; HERAVI, E. J. Convolutional neural networks. In: _____. **Guide to Convolutional Neural Networks: A Practical Application to Traffic-Sign Detection and Classification**. Cham: Springer International Publishing, 2017. p. 85–130. ISBN 978-3-319-57550-6. Disponível em: <https://doi.org/10.1007/978-3-319-57550-6_3>.

B, M. Y. X. Intelligent weight prediction of cows based on semantic segmentation and back propagation neural network. **Front Artif Intell**, Published 2024 Jan 29, v. 7, p.

1299169, 2024.

BALLARD, D. H.; BROWN, C. M. **Computer Vision**. New York: Prentice Hall Professional Technical Reference, 1982. ISBN 978-0-13-165316-0.

BARELLI. **Introdução à Visão Computacional: Uma abordagem prática com Python e OpenCV**. [S.l.]: Casa do Código, 2018.

BOOK, D. L. **As 10 Principais Arquiteturas de Redes Neurais**. 2017. Disponível em: <<http://deeplearningbook.com.br/as-10-principais-arquiteturas-de-redes-neurais/>>. 04 abr. 2024.

BRASIL, Z. **Como a Inteligência Artificial (IA) pode contribuir com a Pecuária Brasileira**. 2024. Disponível em: <<https://zootecniabrasil.com/2024/01/23/como-a-inteligencia-artificial-ia-pode-contribuir-com-a-pecuaria-brasileira/>>. Acesso em: 2024-06-12.

CASTILLO, L. et al. Prediction of live weight in beef heifers using a body volume formula. **Arquivo Brasileiro de Medicina Veterinária e Zootecnia**, Universidade Federal de Minas Gerais, Escola de Veterinária, v. 74, n. 6, p. 1127–1133, Nov 2022. ISSN 0102-0935. Disponível em: <<https://doi.org/10.1590/1678-4162-12886>>.

DENG, L.; YU, D. et al. Deep learning: methods and applications. **Foundations and trends® in signal processing**, Now Publishers, Inc., v. 7, n. 3–4, p. 197–387, 2014.

FILHO, O. G. **Inteligência Artificial e Aprendizagem de Máquina: Aspectos teóricos e aplicações**. Blucher, 2023. 462 p. <https://storage.blucher.com.br/book/pdf_preview/PDF_ia.pdf>. Disponível em: <https://storage.blucher.com.br/book/pdf_preview/PDF_ia.pdf>.

FOUNDATION, R. P. Photography and computer vision with the raspberry pi camera. 2023. Disponível em: <<https://embarcados.com.br/fotografia-e-visao-computacional-com-a-camera-raspberry-pi/>>.

GARCÍA, G. B. et al. **Learning Image Processing with OpenCV**. [S.l.]: Packt Publishing Ltd, 2015.

GONZALEZ, R.; WOODS, R. **Digital Image Processing**. Pearson, 2018. ISBN 9780133356724. Disponível em: <<https://books.google.com.br/books?id=0F05vgAACAAJ>>.

GU, J. et al. Recent advances in convolutional neural networks. **Pattern Recognition**, v. 77, p. 354–377, 2018. ISSN 0031-3203. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0031320317304120>>.

HOU, Z. et al. Body weight estimation of beef cattle with 3d deep learning model: Pointnet++. **Computers and Electronics in Agriculture**, v. 213, p. 108184, 2023. ISSN 0168-1699. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0168169923005720>>.

IBM. **O que é Aprendizado não Supervisionado?** 2024. Disponível em: <<https://www.ibm.com/br-pt/topics/unsupervised-learning>>. Acesso em: 04 abr. 2024.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, n. 7553, p. 436–444, 2015. ISSN 1476-4687. Disponível em: <<https://doi.org/10.1038/nature14539>>.

LIMA, R. de C. A.; GOMES, H. M. **Tutorial de Processamento Digital de Imagens**. 2015. <<http://www.dsc.ufcg.edu.br/~hmg/disciplinas/graduacao/vc-2015.1/Rita-Tutorial-PDI.pdf>>. Acesso em: 13 de junho de 2024.

LUDERMIR, T. B. Título do artigo. **Revista**, v. 351, n. 1, p. 7–14, 2021. Professora titular do Centro de Informática da Universidade Federal de Pernambuco, membro da Ordem Nacional do Mérito Científico, membro da Academia Pernambucana de Ciências e diretora da Rede Nordeste de Inteligência Artificial (lane).

MA, W. **TRANSFORMAÇÃO DIGITAL DA PECUÁRIA DE CORTE INTENSIVA NO BRASIL: TECNOLOGIAS E PERFIL DE ADOÇÃO DIGITAL TRANSFORMATION OF INTENSIVE BEEF LIVESTOCK IN BRAZIL: TECHNOLOGIES AND ADOPTION PROFILE**. 2024. <<https://ainfo.cnptia.embrapa.br/digital/bitstream/doc/1160680/1/TransformacaoDigitalPecuaria.pdf>>.

MA, W. et al. Computer vision-based measurement techniques for livestock body dimension and weight: A review. **Agriculture**, v. 14, p. 306, 02 2024.

MALHOTRA, M. Application of ai/ml approaches for livestock improvement and management. **Livestock diseases and management**, p. 377–394, 2023.

MITCHELL, T. **Machine Learning**. S. l.: McGraw Hill, 1997.

NA, M. H. et al. Automatic weight prediction system for korean cattle using bayesian ridge algorithm on rgb-d image. **Electronics**, v. 11, n. 10, 2022. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/11/10/1663>>.

ONE, D. I. **Machine Learning: Uma Jornada pelo Coração da Inteligência Artificial**. 2024. <<https://www.dio.me/articles/machine-learning-uma-jornada-pelo-coracao-da-inteligencia-artificial>>. Accessed: 2024-06-13.

PENG, Y. et al. A dynamic individual yak heifer live body weight estimation method using the yolov8 network and body parameter detection algorithm. **Journal of Dairy Science**, 2024. ISSN 0022-0302. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S002203022400496X>>.

SONKA, M.; HLAVAC, V.; BOYLE, R. **Image Processing, Analysis, and Machine Vision**. 4th. ed. [S.l.]: engage Learning, 2014.

VETRISILVAN, D.; STALIN, T. **Computer Vision with OpenCV and Python 3: Practical examples workbook**. [S.l.: s.n.], 2017.

VIANA, G. **Diferença entre Aprendizado de Máquina (Machine Learning) e Aprendizagem Profunda (Deep Learning)**. 2024. Accessed: 2024-06-13. Disponível em: <<https://medium.com/@gviana93/diferen%C3%A7a-entre-aprendizado-de-m%C3%A1quina-machine-learning-aprendizagem-profunda-deep-learning-3035e95ba1d1>>.