



ISSN: 2674-8584 V.8 – N.1– 2023

## **CONTAGEM DE GADO NELORE USANDO VISÃO COMPUTACIONAL EM IMAGENS AÉREAS**

### **COUNTING NELORE CATTLE USING COMPUTER VISION IN AERIAL IMAGES**

**Heber Wursmtich Nardes**

Cientista da Computação Preceptor, Faculdade de Ciências Exatas e  
Tecnológicas

Curso de Ciência da Computação

Barra do Bugres – UNEMAT/MT, Brasil.

e-mail: [heber.nardes@unemat.br](mailto:heber.nardes@unemat.br)

#### **Resumo:**

O artigo propõe uma abordagem inovadora para a identificação e contagem automatizada de gado Nelore, utilizando técnicas avançadas de visão computacional. Inicialmente, destaca-se a importância econômica e alimentar da pecuária, especialmente da raça Nelore. A revisão bibliográfica abrange técnicas de visão computacional e sistemas computacionais de contagem de gado, permitindo a comparação de características, funcionalidades, algoritmos e aprendizado de máquina utilizados. Além disso, são propostas métricas de precisão e eficiência para avaliar o desempenho dos sistemas automatizados, comparando-os com métodos tradicionais. O estudo não apenas visa aprimorar a gestão do rebanho Nelore, mas também contribui para o avanço científico na aplicação prática da visão computacional na pecuária. Ao oferecer suporte prático aos produtores rurais na seleção e implementação de sistemas eficientes, busca-se promover a modernização e aprimoramento das práticas de manejo de rebanhos, alinhando-se às demandas atuais do setor agropecuário.

**Palavras-chave:** Nelore, visão computacional e pecuária.

## **Abstract:**

The article proposes an innovative approach for the automated identification and counting of Nelore cattle, using advanced computer vision techniques. Initially, the economic and food importance of livestock farming, especially the Nelore breed, stands out. The literature review covers computer vision techniques and livestock counting computer systems, allowing the comparison of characteristics, functionalities, algorithms and machine learning used. Furthermore, accuracy and efficiency metrics are proposed to evaluate the performance of automated systems, comparing them with traditional methods. The study not only aims to improve the management of the Nelore herd, but also contributes to scientific advancement in the practical application of computer vision in livestock farming. By offering practical support to rural producers in the selection and implementation of efficient systems, the aim is to promote the modernization and improvement of herd management practices, in line with the current demands of the agricultural sector.

**Keywords:** Nelore, computer vision and livestock.

## **1. INTRODUÇÃO**

A pecuária desempenha um papel crucial na produção de alimentos e no desenvolvimento econômico, sendo a raça Nelore uma das mais importantes no cenário agropecuário. Reconhecida por sua adaptabilidade a diferentes ambientes e resistência a condições adversas, a criação de gado Nelore representa uma esfera crucial na indústria pecuária, tanto no Brasil quanto em outros países onde a raça é criada.

Diante da importância econômica e alimentar da pecuária Nelore, a busca por métodos mais eficientes e precisos de identificação e contagem do gado se torna imperativa. Os métodos tradicionais, muitas vezes suscetíveis a erros e demandando extensivo trabalho manual, confrontam os desafios inerentes à vastidão e complexidade das áreas de pastagem onde a raça Nelore é criada.

Nesse contexto, a aplicação de avançadas técnicas de visão computacional em imagens aéreas surge como uma solução promissora. Este artigo propõe uma abordagem inovadora para a identificação e contagem automatizada de gado Nelore,

visando não apenas aprimorar a gestão do rebanho, mas também contribuir para o avanço científico na aplicação prática da visão computacional na pecuária.

Ao considerar a relevância específica da raça Nelore, este estudo busca oferecer subsídios importantes para auxiliar os produtores rurais na seleção e implementação de sistemas computacionais de contagem de gado eficientes e adequados às suas necessidades específicas, promovendo a modernização e aprimoramento das práticas pecuárias voltadas para essa importante linhagem de gado.

## **2. VISÃO COMPUTACIONAL**

A visão computacional é uma área que permite o desenvolvimento de sistemas de contagem de gado baseados em análise de imagens. A aplicação de algoritmos de processamento de imagem, detecção e rastreamento de objetos pode fornecer informações precisas sobre a quantidade e movimentação do gado (KELLENBERGER e MARCOS, 2018).

A visão computacional tem sido amplamente utilizada como uma abordagem para rastreamento de gado, usando algoritmos para processamento de imagens, detecção de objetos e otimização de objetos. Esta abordagem tem sido eficaz na obtenção de resultados precisos.

### **2.1 Técnicas de Visão Computacional**

Câmeras Inteligência usa câmeras de alta resolução instaladas em áreas estratégicas podem ser usadas para capturar imagens de rebanho. Algoritmos de visão computacional analisam essas imagens para contar os animais. Andrew e Greatwood (2017) citou no seu artigo o conjunto de dados AerialCattle2017 consiste em 34 vídeos aéreos de rebanhos de gado em um campo agrícola. Cada vídeo, com cerca de 20 segundos de duração, é capturado de uma perspectiva aérea, e regiões específicas com vagas são gravadas para criar vídeos individuais. Após esse


processo, o conjunto de dados resultante possui 23 indivíduos, totalizando 160 vídeos, com uma média de 7 ocorrências por indivíduo e um desvio padrão de 3,87. A aquisição dos vídeos foi feita usando um drone DJI Inspire MKI, sobrevoando aproximadamente 30 jovens Frísios Holandeses em uma fazenda veterinária. A filmagem ocorreu durante uma hora, variando a altura do drone de 25 metros para a mais baixa em incrementos de 5 metros. Isso permitiu que as vacas se acostumassem à presença do drone. Na fase de rotulagem e corte verdadeiro, as caixas delimitadoras foram anotadas manualmente no primeiro quadro de cada vídeo e usadas para categorizar os dados. O algoritmo KCF de rastreamento foi aplicado para gerar caixas delimitadoras para os quadros subsequentes, e as regiões recortadas foram salvas como vídeos independentes, agrupados por rótulos de classe originais.

Sistemas de Reconhecimento Facial são Tecnologias avançadas de visão computacional estão sendo desenvolvidas para identificar bovinos com base em padrões faciais únicos. Isso pode ser útil em sistemas de monitoramento automatizado. Alexandre Brito (2021) discute a aplicação de tecnologias alternativas, como visão computacional, processamento de imagens e reconhecimento facial, visando melhorar a eficiência e reduzir o impacto nos animais. O trabalho propõe a construção de um conjunto de dados de faces de gado para desenvolver modelos de identificação e detecção facial, explorando diferentes metodologias e abordagens utilizadas no reconhecimento facial humano. foram utilizadas várias técnicas de visão computacional para a construção do conjunto de dados com imagens de faces de bovinos. Uso de algoritmo base utilizado no ramo da visão computacional, como o PCA (Principal Component Analysis) ou a técnica Eigenfaces, que utiliza componentes principais como um dos pilares. O PCA é um algoritmo versátil que já foi amplamente estudado e aplicado em diversas áreas da visão computacional. Ele é conhecido por sua facilidade de correção e pela capacidade de remover variações correlacionadas, o que acelera o tempo de treinamento dos algoritmos. Seu objetivo principal é encontrar as principais variações de dados, chamadas de componentes principais, e projetar os dados nesse novo espaço de menor dimensão.

A técnica Eigenfaces é um exemplo de aplicação do PCA na área de reconhecimento e detecção facial. O termo "Eigenfaces" refere-se aos autovetores resultantes do processo de PCA. Esses vetores são considerados como rostos médios ou protótipos que representam a variação das faces apresentadas no conjunto de dados.

O processo de aplicação da técnica Eigenfaces envolve as seguintes etapas:

- **Preparação do conjunto de dados:** As imagens aparentes do conjunto de dados são convertidas em formato vetorial, onde cada imagem é tratada como um vetor de intensidades de pixels.
- **Redução de dimensionalidade:** Através do PCA, é realizada uma análise estatística dos dados, identificando as principais variações. Esses conhecidos, também conhecidos como componentes principais, são vetores que representam as formas e características mais importantes presentes nas imagens.
- **Projeção dos dados:** As imagens de entrada são projetadas no espaço de menor dimensão definida pelos componentes principais. Essa projeção permite representar cada imagem como uma combinação linear desses componentes.
- **Reconhecimento e detecção de faces:** Com base na representação das imagens no espaço de menor dimensão, é possível aplicar técnicas de classificação e detecção para reconhecer e detectar faces em novas imagens.



Fonte: Alexandre Brito (2020)




As técnicas de PCA e Eigenfaces possuem a vantagem de serem computacionalmente eficientes e, ao mesmo tempo, capazes de representar e identificar características importantes das faces. No entanto, essas técnicas podem apresentar limitações quando as variações de iluminação, poses ou expressões visíveis são relevantes, pois não levam em consideração essas variações ao modelar os componentes principais. Portanto, é importante considerar outras técnicas adicionais ou aprimoradas para lidar com esses desafios.

Garcia e Vieira (2019) usou duas abordagens distintas para a detecção de gado em imagens. A primeira estratégia envolveu o uso de Redes Neurais Convolucionais (CNNs) para gerar um mapa de calor de probabilidade, revelando as possíveis localizações dos animais. Essa abordagem empregou uma técnica de varredura da imagem por meio de uma janela deslizante, permitindo a captura de partes do animal em vários blocos de imagem. Sua eficiência e rapidez tornam essa



abordagem adequada para diversas situações de detecção. A segunda abordagem desenvolveu técnicas que resultaram na geração de caixas delimitadoras em torno dos objetos de interesse, neste caso, o gado. Utilizou-se a arquitetura YOLO v2, reconhecida por sua alta velocidade na detecção de objetos em imagens. Essa estratégia contribuiu para uma detecção precisa da presença de gado, gerando caixas delimitadoras que circundam os animais identificados. A escolha do YOLO v2 ressalta a ênfase na eficiência e rapidez para a detecção de animais em imagens de UAV. Ambas as abordagens trouxeram eficácia na identificação da localização do gado nas imagens, desempenhando um papel crucial em estudos de detecção e concentração de animais em ambientes de campo. A combinação dessas técnicas de aprendizado profundo oferece uma variedade de opções para pesquisadores e profissionais envolvidos em monitoramento de animais, agricultura e conservação.

Já Midlej e Lima (2020), O pré-processamento de imagens para visão computacional, inclui uma etapa crucial de conversão do sistema de núcleos RGB para o sistema HSV. Esse procedimento é essencial para otimizar processos como a segmentação, permitindo uma representação mais adequada dos canais de tonalidade, saturação e brilho. Na redução de ruídos, utiliza-se o filtro gaussiano, que não apenas suaviza a imagem, mas também melhora a eficácia dos filtros de detecção de borda. Os processos de erosão e dilatação são empregados para remover partículas ou ruídos remanescentes na imagem, afetando as áreas segmentadas. A erosão, em particular, pode facilitar a separação de bovinos quando estão conectados, mas não completamente unidos, corrigindo detecções de bordas e aprimorando a precisão do programa. A segmentação por cor, realizada no sistema de núcleos HSV, é eficaz quando o objeto de interesse possui características específicas em relação ao restante da imagem. A definição de valores mínimos e máximos nos canais de tonalidade, saturação e brilho no HSV destaca o objeto desejado.



Fonte: Midlej e Lima (2020)

Por fim, o software que emprega um filtro de detecção de contornos, e para cada contorno identificado, são avaliados a área e o raio do menor círculo que o envolve. Valores discrepantes indicam a ausência do objeto procurado, contribuindo para a precisão do programa na detecção de bovinos nas imagens.

### 2.1.1 Algoritmos com biblioteca OpenCV e aprendizado de máquina

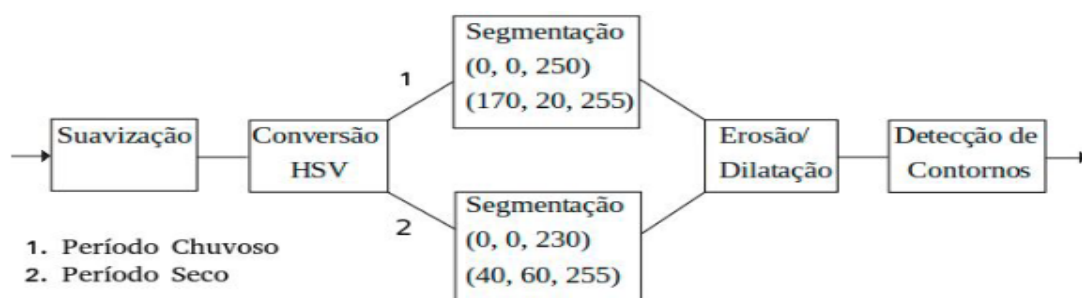
A aplicação de algoritmos e técnicas de aprendizado de máquina vem destacando na contagem de gado. Estudos relatam o uso de redes neurais, algoritmos



de classificação e regressão para aprimorar a precisão dos sistemas de contagem. O treinamento desses algoritmos com conjuntos de dados relevantes pode contribuir para melhorar a capacidade de detecção e contagem dos animais.


Midlej e Lima (2020) descreve minuciosamente o desenvolvimento de um software inovador voltado para a detecção de bovinos brancos em imagens, utilizando como base a linguagem de programação Python e a poderosa biblioteca de visão computacional OpenCV. O projeto passou por extensivos testes, buscando otimizar as configurações e os melhores fluxos de processos que proporcionassem os resultados na detecção de bovinos brancos nas imagens selecionadas.

O algoritmo desenvolvido para os períodos de seca e chuva é cuidadosamente delineado em cinco passos essenciais. Inicia-se com a suavização gaussiana da imagem, seguida pela conversão do sistema de núcleos RGB para o espaço HSV. A segmentação da imagem ocorre posteriormente, com parâmetros específicos para cada período, seguidos por uma série de operações de erosão e dilatação. A detecção de contornos encerra o processo. O fluxograma resultante é apresentado na figura abaixo, destacando cada etapa e permitindo uma compreensão visual do percurso até a detecção precisa dos bovinos. Divergências entre os fluxogramas para períodos secos e chuvosos são apontadas, principalmente na fase de segmentação, onde valores específicos nos canais do sistema de núcleos HSV são determinantes.



Fonte: Midlej e Lima (2020)

Após a execução do fluxograma, é realizada uma contagem dos contornos detectados. Cada contorno é submetido ao projeto da área e do raio do menor círculo que o envolve completamente. Valores mínimos e máximos são estabelecidos empiricamente para garantir que apenas contornos que correspondam corretamente a um bovino sejam considerados. A Figura abaixo ilustra vividamente todo o processo de detecção, classificação e contagem de bovinos brancos, exemplificado em uma imagem específica.



Fonte: Midlej e Lima (2020)

Ribeiro e Guedes (2019) apresenta uma abordagem robusta para a contagem de objetos em imagens, destacando a implementação de um programa em Python. Inicialmente, a imagem a ser comprovada é submetida à aplicação do filtro de escala de cinza, seguido por filtros de suavização que visam eliminar ruídos e imperfeições presentes na imagem. Posteriormente, a aplicação de limites é crucial para definir os contornos dos objetos a serem detectados. Destacando a importância das transformações morfológicas na obtenção de resultados precisos, refinando os contornos e evitando problemas comuns no processamento de imagens. Detectores

de objetos binários entram em cena para a contagem efetiva de objetos de estudo na imagem. A escolha da biblioteca OpenCV é fundamentada em sua capacidade de oferecer mais de mil algoritmos secundários para três análises de visão computacional, processamento de imagem e vídeo, entre outros. O programa passa por uma série de etapas, cada uma desempenhando um papel crucial na contagem eficaz de objetos. A utilização de filtros e transformações é vital para lidar com a complexidade das imagens e garantir resultados confiáveis.

Secretário e Pires (2018) aborda a complexidade da análise de imagens de células, limitando a dificuldade em desenvolver algoritmos universais devido à grande variação entre amostras. Duas estratégias são exploradas: inicialmente, a detecção de contornos utilizando OpenCV, seguida pela implementação de uma rede neural convolucional (CNN) com o auxílio da biblioteca Keras. Destacando as limitações da abordagem inicial, que exigiam a intervenção do usuário devido à heterogeneidade das imagens coletadas, cada uma exigência de parâmetros específicos. A solução adotada foi o desenvolvimento de uma rede neural que "aprende" a considerar diferentes tipos de células nas imagens de amostra.

A CNN divide os objetos em duas classes distintas: células e plano de fundo da imagem. A detecção é realizada através das coordenadas das células, e uma caixa é projetada ao redor delas, reduzindo a probabilidade de serem células. O programa informa ao usuário a quantidade de células encontradas, fornecendo uma solução mais automática e eficiente. O treinamento da rede envolveu uma ampla quantidade de dados, levemente modificados para aumentar a diversidade, e a validação e teste da precisão da rede. A implementação de funções gráficas do OpenCV encerra o processo, apresentando visualmente os resultados ao usuário.

Simplificando tudo Ribeiro e Guedes(2019), usou programação em Python foi implementado com o objetivo de identificar com o OpenCV e contar objetos em imagens. Os passos para realizar a contagem de gado foram os seguintes:

1. Aplicou um filtro de escala de cinza na imagem.
2. Executou filtros de suavização para remoção de ruídos e imperfeições.
3. Utilizou de limiarização para definir os contornos dos objetos a serem detectados.
4. Realizou de transformações morfológicas para refinar os resultados e evitar problemas comuns no processamento de imagens.
5. Utilizou de detectores de objetos binários para contar os objetos de estudo na imagem utilizando a programação Python.

Tanto como Midlej e Lima (2020) e Garcia e Vieira (2019), utilizaram Python que é considerada uma das melhores linguagens de programação para inteligência artificial devido a sua sintaxe simples e legível, ampla disponibilidade de bibliotecas e frameworks específicos para IA, uma comunidade ativa e suporte, integração com outras linguagens e sua ampla adoção pela indústria.

## 2.2 Comparação entre a identificação por radiofrequência (RFID) e a visão computacional

A visão computacional pode ser uma excelente alternativa para a contagem de bovinos, especialmente em ambientes nos quais a identificação individual não é necessária. A tecnologia de identificação por radiofrequência (RFID) tem sido amplamente utilizada no gerenciamento de gado porque permite o rastreamento e identificação de animais e o monitoramento de seu histórico de saúde e alimentação. O uso do RFID na pecuária tem se tornado cada vez mais comum, sendo exigido em alguns casos por órgãos reguladores para garantir a rastreabilidade e segurança alimentar.

Silva e Minadeo (2018) usou uma implementação da identificação eletrônica por RFID na peculiaridade do corte aborda vários problemas importantes, além dos desafios técnicos. Um dos desafios é o custo associado à implementação do sistema,

que inclui a aquisição de transponders (dispositivos de identificação eletrônica) e dispositivos de leitura e gravação. Muitos produtores podem considerar essas despesas elevadas. Uma barreira adicional é a necessidade de infraestrutura tecnológica para o processamento e armazenamento dos dados gerados pelo sistema. Os investimentos em sistemas de tecnologia de informação são necessários para a criação de um banco de dados que registra e monitora as informações dos animais.

O sistema de identificação por radiofrequência, ou RFID, funciona por meio de dispositivos eletrônicos conhecidos como transponders, que são aplicados a objetos que detectam. Estes transponders possuem uma antena para se comunicar com leitores RFID e um chip que armazena informações. O transponder é energizado por um campo eletromagnético gerado por um leitor RFID que emite um sinal de radiofrequência. O leitor recebe a resposta do transponder enviando as informações no chip. Um sistema de software pode processar essas informações para que o leitor leia e realize diversas tarefas, como identificar um objeto, rastrear sua localização ou coletar dados sobre ele. Como ilustrado na imagem a seguir:



Fonte: O autor, 2023

É importante considerar que a escolha da tecnologia depende das



necessidades específicas do produtor, do ambiente e dos recursos disponíveis. A visão computacional pode oferecer uma solução eficiente e econômica para a contagem de bovinos em muitos casos, mas a abordagem mais adequada pode variar de acordo com as circunstâncias específicas.

O SISBOV (Sistema Brasileiro de Identificação e Certificação de Origem Bovina e Bubalina) foi criado pelo governo brasileiro em 2002, em resposta às turbulências nos mercados externos. Instituído pelo Ministério da Agricultura, Pecuária e Abastecimento (MAPA), o sistema tinha como objetivo caracterizar a origem, o estado sanitário, a produção e a produtividade da pecuária nacional, garantindo a segurança dos alimentos provenientes da atividade (David, 2008). A principal mudança introduzida foi a obrigatoriedade da identificação individual de todos os bovinos e bubalinos no Brasil, sejam nascidos localmente ou importados. Antes, a pecuária exportava rebanhos inteiros, marcados apenas com fogo para identificação do dono. Com a necessidade de identificação individual, o foco da atividade mudou para o animal como indivíduo, exigindo novas regras de identificação, que podem variar de marcações no corpo dos dispositivos visuais e eletrônicos.

O SISBOV, por meio da Base Nacional de Dados (BND), centraliza informações sobre animais, propriedades rurais e indústrias frigoríficas, garantindo qualidade e saúde aos rebanhos brasileiros. Em 2006, uma nova versão do SISBOV foi lançada, buscando alinhar as regras de rastreabilidade da carne brasileira com padrões internacionais, atendendo às exigências dos importadores. Atualmente, o Comitê Técnico Consultivo do Eras/Sisbov busca ajustar a regulamentação para tornar o sistema mais simples e compatível com o padrão europeu, garantindo a qualidade e a competitividade do produto brasileiro no mercado global.

### 2.2.1 Custo de cada projeto

A implementação de um kit de tags em uma população de 1000 gatos envolve diversos fatores que são importantes para o custo total do projeto. Entre esses fatores,

destacam-se as tags utilizadas, os leitores e equipamentos necessários, o software de gerenciamento e eventuais serviços profissionais. O custo das tags é um elemento central, variando de acordo com o tipo escolhido, como RFID, visual ou eletrônico, e uma marca específica. Uma estimativa média coloca o custo por tag entre US\$ 2 e US\$ 5. Assim, para uma população de 1.000 gatos, o custo mínimo das tags seria de US\$ 2.000, enquanto o custo máximo atingiria US\$ 5.000.

Além das tags, a necessidade de leitores e outros equipamentos para gerenciar as informações associadas às tags pode adicionar custos significativos. O preço dos leitores RFID que custa entre a US\$ 1.600 a US\$ 1.800, por exemplo, pode variar consideravelmente, desde algumas centenas até alguns milhares de dólares.

A implementação de um software de gerenciamento para monitorar as informações das tags também deve ser considerada. Os custos de software variam amplamente, desde soluções gratuitas até sistemas mais complexos que podem exigir investimentos substanciais. Além disso, serviços profissionais, como instalação, treinamento e suporte técnico, podem ser necessários, contribuindo para os custos totais do projeto.

Ao analisar o custo individual por animal, considerando o custo mínimo de US\$ 2 por etiqueta, o valor seria de US\$ 2 por animal. No caso do custo máximo de US\$ 5 por etiqueta, o custo individual seria de US\$ 5 por animal. Essas estimativas fornecem uma visão geral do investimento necessária para a implementação do kit de tags em uma população de gado, sendo essencial uma avaliação específica de fornecedores para obter cotações precisas com base nas necessidades particulares do projeto.

A escolha entre contagem de gado usando visão computacional em imagens aéreas e RFID (Identificação por Radiofrequência) depende de uma série de fatores que podem influenciar a eficiência e eficácia do sistema em diferentes contextos. A visão computacional oferece a vantagem de não exigir marcação individual de cada

animal, permitindo a análise de grandes áreas em uma única imagem aérea. No entanto, esta abordagem pode ser afetada por condições climáticas e de iluminação, além de exigir hardware específico, como drones e câmeras de alta resolução. O desenvolvimento de algoritmos personalizados também pode ser complexo. Por outro lado, o RFID oferece uma identificação individual precisa para cada animal, sendo menos impactado por condições ambientais adversas. Essa tecnologia é madura e amplamente utilizada na pecuária, apresentando-se como uma opção robusta para a contagem de gado. No entanto, é necessária a aplicação de tags RFID em cada animal e está limitada ao alcance das antenas RFID. Além disso, oferece menos informações adicionais comparadas à visão computacional.

Ao tomar decisões entre essas tecnologias, é crucial considerar diversos fatores. O custo é uma consideração importante, sendo o RFID ambientalmente mais econômico para grandes rebanhos, enquanto a visão computacional pode exigir investimentos significativos em hardware e software. A complexidade do ambiente, como a presença de florestas densas ou terrenos irregulares, pode influenciar a escolha, com a visão computacional sendo mais desafiadora em condições adversárias. A manutenção também deve ser ponderada, pois o RFID tende a ser menos suscetível a falhas decorrentes de condições ambientais adversas, enquanto a visão computacional pode exigir mais cuidados. O fornecimento de informações adicionais sobre a condição física dos animais pode ser um fator decisivo. Se esta informação é crítica, a visão computacional pode ser mais adequada para fornecer dados detalhados.

Contudo, a escolha entre visão computacional e RFID dependerá das prioridades específicas do projeto, do ambiente operacional e das informações adicionais possíveis. Consultar especialistas em ambas as tecnologias pode ser crucial para avaliar qual delas melhor atende às necessidades específicas de restrição de gado em um determinado contexto.

### **3. AVALIAÇÃO DE DESEMPENHO E MÉTRICAS**

A busca por soluções tecnológicas na pecuária tem impulsionado a aplicação de algoritmos e sistemas para identificação de gado, melhora o manejo e monitoramento dos rebanhos. Neste contexto, analisaremos artigos que propõem diferentes abordagens para a identificação de bovinos, destacando métricas de desempenho e resultados obtidos.

Midlej e Lima (2020) aborda a contagem de bovinos em imagens aéreas, considerando desafios como chuva, seca e obstáculos visuais. Utilizando um conjunto diversificado de imagens, o algoritmo alcançou 89,1% de reconhecimento, com 6,5% de erro, resultando em uma efetividade de 82,6%. Obstáculos visuais, como árvores e proximidade entre animais, foram identificados como principais causas de erros.

Ribeiro e Guedes(2019) concentra-se na detecção de animais em imagens aéreas, considerando diferentes parâmetros, como limites de limiarização e regiões de análise. Ao avaliar animais de núcleos distintos, o algoritmo alcançou taxas de certo, destacando desafios quando os animais possuíam cores semelhantes ao ambiente. A taxa de acerto variou de 34,8% a 92,4%, dependendo das condições do ambiente.

Andrew(2017) propõe uma abordagem baseada em redes neurais para detecção, localização e identificação de gado em imagens e vídeos. Utilizando a arquitetura Faster R-CNN e resultados cruzados, o algoritmo atingiu quase perfeito na localização correta dos animais, com valores de mapa trazendo uma eficácia notável.

Alexandre Brito(2021) destaca a aplicação de reconhecimento facial bovino em ambientes controlados, utilizando análise de componentes principais (PCA). Com uma base de 31 classes de gado e 783 imagens, o algoritmo alcançou acurácia superior a 90%, superando resultados obtidos em abordagens semelhantes.

A diversidade nos métodos de identificação de gado reflete a complexidade do desafio, variando desde condições climáticas adversárias até ambientes

controlados. Cada abordagem apresenta especificações específicas de desempenho, destacando a importância de considerar o contexto de aplicação e os desafios inerentes a cada cenário. Estas análises reforçam a necessidade de adaptação de técnicas conforme as condições reais de campo, confirmando que não existe uma solução única para todos os contextos. O avanço nesse campo crucial da pecuária promete não apenas melhorar a eficiência operacional, mas também contribuir para o bem-estar animal e a sustentabilidade do setor.

#### **4. GESTÃO AGROPECUÁRIA E TOMADA DE DECISÃO COM O USO DA VISÃO COMPUTACIONAL**

De acordo com Valadão e Dopcke (2022) a tecnologia na agricultura já permite avanços como contagem de animais e detecção por drones e câmeras, trazendo benefícios como monitoramento da saúde animal e determinação dos melhores dados para reduzir. O setor agrícola, impulsionado por agtechs (Agtech ou Agrotech é uma startup com foco no agronegócio. Ela utiliza a tecnologia para beneficiar as empresas que trabalham com agropecuária e trazer soluções para problemas comuns) e empreendedores, busca aumentar a produção de forma sustentável, utilizando a Inteligência Artificial para atender pequenos agricultores em mercados emergentes. O crescimento do setor cria oportunidades para o setor privado, mas desafios como conectividade e falta de mão de obra especializada persistem. A colaboração entre governos, investidores e indústria é crucial para enfrentar esses desafios e contribuições para a Revolução Agro 4.0, embora obstáculos culturais ainda possam dificultar a implementação no Brasil.

A gestão agropecuária está passando por uma revolução tecnológica impulsionada pela visão computacional. Essa abordagem inovadora vai além de contar e identificar animais automaticamente; ela se tornou um pilar essencial para uma gestão mais eficiente e sustentável. A seguir, destacamos como a visão computacional está evoluindo para a agricultura e a pecuária, fornecendo informações valiosas e apoiando uma tomada de decisões:



- **Contagem e Identificação Automática de Animais:** A visão computacional permite a detecção e identificação automática de animais, simplificando o monitoramento do tamanho do rebanho. Essa automação é especialmente benéfica em fazendas de gado, oferecendo uma visão precisa do crescimento do rebanho ao longo do tempo.
- **Monitoramento de Comportamento Animal:** Analisando padrões de comportamento, a visão computacional oferece insights cruciais sobre a saúde e o bem-estar dos animais. Ao detectar comportamentos anormais, possibilita intervenções rápidas, garantindo o cuidado adequado.
- **Identificação Precoce de Doenças:** A capacidade de identificar sinais visuais de doenças em estágios iniciais é vital. A visão computacional analisa imagens de plantas e animais, permitindo a detecção precoce de problemas de saúde e a implementação de medidas preventivas.
- **Monitoramento do Estado das Pastagens:** Ao analisar imagens de pastagens, a visão computacional identifica áreas de Sobrepastejo onde ocorre quando os animais consomem a forragem, levando à manipulação da pastagem e o Subpastejo que é oposto, com consumo insuficiente, resultando em cobertura vegetal excessiva. Ambos prejudicam a sustentabilidade e a produtividade. Isso auxilia na gestão eficiente dos recursos alimentares para o gado, contribuindo para práticas agrícolas mais sustentáveis.
- **Gestão Eficiente e Sustentável:** Implementar soluções de visão computacional capacita agricultores e pecuaristas para tomar decisões mais informadas. Isso resulta em uma gestão mais eficiente e sustentável, otimizando processos de produção e promovendo práticas agrícolas mais inteligentes.
- **Otimização dos Processos:** A automação proporcionada pela visão computacional reduz a dependência de intervenções manuais, economizando tempo

e recursos. Isso permite que os agricultores se concentrem em atividades estratégicas.

- **Melhoria na Produtividade:** A combinação de monitoramento preciso, detecção precoce de problemas e tomada de decisões informadas resulta em uma melhoria geral na produtividade. Os agricultores trabalham proativamente, minimizando perdas e maximizando o potencial de suas operações.

Contudo, a visão computacional na gestão agropecuária não é apenas uma ferramenta tecnológica; é uma aliada na busca por práticas agrícolas mais conscientes, sustentáveis e eficazes. Essa revolução está moldando o futuro da agricultura, promovendo um equilíbrio entre inovação e responsabilidade ambiental.

## **5. CONCLUSÃO/ CONSIDERAÇÕES FINAIS**

A aplicação da visão computacional na identificação e contagem automatizada de gado Nelore representa um avanço significativo para a pecuária, oferecendo benefícios substanciais para a gestão eficiente e sustentável dos rebanhos.

Diante da revisão bibliográfica realizada, foi possível identificar e comparar diversas técnicas de visão computacional aplicadas à identificação e contagem de animais na pecuária. A análise dos artigos científicos e técnicos selecionados revelou a diversidade de sistemas computacionais de contagem de gado, cada um com suas características e funcionalidades específicas, além do uso de diferentes algoritmos e técnicas de aprendizado de máquina.

A avaliação da precisão e eficiência desses sistemas demonstrou avanços significativos, proporcionando vantagens em relação aos métodos tradicionais de contagem. No entanto, também foram identificadas algumas limitações, especialmente relacionadas a condições ambientais adversas e desafios específicos de cada contexto de aplicação.

Os resultados obtidos fornecem subsídios importantes para auxiliar os produtores rurais na seleção e implementação de sistemas computacionais de contagem de gado eficientes e adequados às suas necessidades específicas. Além disso, evidenciam a relevância da visão computacional para a pecuária Nelore, ao possibilitar a automação de processos, a redução de erros e a demanda por mão de obra, e a obtenção de informações precisas sobre o rebanho.

Dessa forma, a aplicação da visão computacional na contagem do gado Nelore não apenas representa um avanço tecnológico, mas também contribui para a modernização e aprimoramento das práticas pecuárias, promovendo a eficiência operacional, o bem-estar animal, a sustentabilidade do setor e a produção de alimentos de qualidade para a população.

## REFERÊNCIAS

Kellenberger B., Marcos D., TUIA D.(2018). **Detecting mammals in UAV images: Best practices to address a substantially imbalanced dataset with deep learning.** Remote Sensing of Environment. Link: <https://www.sciencedirect.com/science/article/abs/pii/S0034425718303067>

Andrew W., Greatwood C., Burghardt T. (2017). **Visual localisation and individual identification of holstein friesian cattle via deep learning.** Proceedings of the IEEE international conference on computer vision workshops. Link: [https://openaccess.thecvf.com/content\\_ICCV\\_2017\\_workshops/w41/html/Andrew\\_Visual\\_Localisation\\_and\\_ICCV\\_2017\\_paper.html](https://openaccess.thecvf.com/content_ICCV_2017_workshops/w41/html/Andrew_Visual_Localisation_and_ICCV_2017_paper.html)

Alexandre Brito (2021). **Reconhecimento Facial Bovino: uma alternativa aos Métodos Tradicionais de Rastreamento. Engenharia de Controle e Automação** — Universidade de Caxias do Sul, Área de conhecimento de ciências exatas e engenharias – Caxias do Sul/RS, Brasil. Link: <https://repositorio.ucs.br/xmlui/handle/11338/9364;jsessionid=CBD94A22C706225268DE7F1C212170E7>

Garcia J. A. B., Vieira L. K., Teixeira T. S., Menezes P. S. (2019). **A Study on the Detection of Cattle in UAV Images Using Deep Learning.** Embrapa Informática Agropecuária, Campinas, São Paulo e

Embrapa Pecuária Sudeste, São Carlos, São Paulo, Brasil. Link: <https://www.mdpi.com/1424-8220/19/24/5436>

Midlej J. E. S., Lima J. O. F. (2020). **Detecção e Contagem de Bovinos em Imagens Aereas utilizando Visão Computacional**. Departamento de Ciências Exatas e Tecnológicas, Universidade Estadual de Santa Cruz (UESC) – Ilhéus, BA – Brasil. Link: <https://sol.sbc.org.br/index.php/erbase/article/view/15462>

Ribeiro, N. G. Vi., Guedes, G. B. e Bardieri, T. T. (2019). **Aplicação de algoritmos de visão computacional na contagem de gado por meio de processamento de imagens aéreas**. Instituto Federal de Educação, Ciências e Tecnologia de São Paulo, Campus Hortolândia, São Paulo – Brasil. Link: <https://revistas.setrem.com.br/index.php/reabtic/article/view/343>

Secretário J. H. A., Pires R. (2018). **Uso de visão computacional para contagem automática de células em imagens obtidas por microscópios**. IFSP – Campus de São Paulo - Brasil. Link: <https://regrasp.spo.ifsp.edu.br/index.php/regrasp/article/view/234>

Silva E. J., Minadeo R. (2018). **Sistema RFID: Vantagens e Desvantagens Observadas na Implementação em Estudos de Casos**. Universidade de Brasília – UNB, Brasil. Link: [https://www.researchgate.net/profile/Roberto-Minadeo/publication/329921526\\_SISTEMA\\_RFID\\_VANTAGENS\\_E\\_DESVANTAGENS\\_OBSERVADAS\\_NA\\_IMPLMENTACAO\\_EM\\_ESTUDOS\\_DE\\_CASOS/links/5c2381d7a6fdccfc706a2556/SISTEMA-RFID-VANTAGENS-E-DESVANTAGENS-OBSERVADAS-NA-IMPLEMENTACAO-EM-ESTUDOS-DE-CASOS.pdf](https://www.researchgate.net/profile/Roberto-Minadeo/publication/329921526_SISTEMA_RFID_VANTAGENS_E_DESVANTAGENS_OBSERVADAS_NA_IMPLMENTACAO_EM_ESTUDOS_DE_CASOS/links/5c2381d7a6fdccfc706a2556/SISTEMA-RFID-VANTAGENS-E-DESVANTAGENS-OBSERVADAS-NA-IMPLEMENTACAO-EM-ESTUDOS-DE-CASOS.pdf)

David L. R. (2008). **Sistema de controle de animais de corte através da tecnologia RFID**. Faculdade de Tecnologia e Ciências Sociais Aplicada (FATECS). UNICEUB. Brasília – Distrito Federal, Brasil. Link: <https://repositorio.uces.br/xmlui/handle/11338/9364;jsessionid=CBD94A22C706225268DE7F1C212170E7w>

Valadão L., Dopcke G. (2022). **Além de gigantes como IBM, Intel e Microsoft, empresas do agronegócio, sobretudo as agtechs, têm despertado para o potencial da visão computacional para identificar padrões em escala**, Revista EY, Campinas – São Paulo, Brasil. Link: [https://www.ey.com/pt\\_br/agencia-ey/noticias/a-visao-computacional-na-transformacao-para-a-agropecuaria-4-0](https://www.ey.com/pt_br/agencia-ey/noticias/a-visao-computacional-na-transformacao-para-a-agropecuaria-4-0)