

MONITORAMENTO DO COMPORTAMENTO DE BOVINOS PARA APOIO A GRANDES FAZENDAS E MANEJO DE REBANHOS

Kauã Gabriel Silva de Lima

kgsl@discente.ifpe.edu.br

Orientador(a): Diogo Lopes da Silva

diogo.lopes@palmares.ifpe.edu.br

RESUMO

A pecuária desempenha um papel crucial na economia brasileira, destacando-se na produção e exportação de carne bovina. Entretanto, a bovinocultura de corte enfrenta desafios relacionados ao manejo eficiente dos recursos e ao bem-estar animal. O ciclo produtivo prolongado e as elevadas exigências nutricionais do gado de corte tornam o retorno financeiro mais demorado, exigindo estratégias que otimizem o manejo e garantam a saúde dos animais. Neste contexto, o monitoramento comportamental dos bovinos surge como uma ferramenta estratégica. Este trabalho propõe o desenvolvimento de um sistema automatizado de monitoramento que utiliza *deep learning* para identificar e classificar atividades comportamentais dos bovinos, como beber água, se alimentar, deitar e permanecer em pé, a partir de imagens obtidas no ambiente de criação. A solução visa acompanhar continuamente os animais, identificando padrões e irregularidades comportamentais que possam indicar a necessidade de intervenções para assegurar o bem-estar e aumentar a produtividade. O sistema, direcionado à agricultura de precisão, fornece informações relevantes para decisões estratégicas, promovendo uma gestão mais sustentável e eficiente na pecuária contemporânea.

Palavras-chaves: Redes Neurais Convolucionais, Bem-estar animal, Monitoramento comportamental, pecuária.

ABSTRACT

Livestock farming plays a crucial role in the Brazilian economy, particularly in beef production and exportation. However, beef cattle farming faces challenges related to efficient resource management and animal welfare. The prolonged production cycle and high nutritional demands of beef cattle result in delayed financial returns, necessitating strategies to optimize management and ensure animal health. In this context, monitoring cattle behavior emerges as a strategic tool. This study proposes the development of an automated monitoring system utilizing deep learning to identify and classify cattle behavioral activities, such as drinking, feeding, lying down, and standing, from images obtained in the herd's resting and confinement environment. The solution aims to continuously monitor the animals, identifying behavioral patterns

and irregularities that may indicate the need for interventions to ensure welfare and increase productivity. The system, aimed at precision agriculture, provides relevant information for strategic decisions, promoting more sustainable and efficient management in contemporary livestock farming.

Keywords: Convolutional Neural Networks, Animal Welfare, Behavioral Monitoring, Livestock.

1 INTRODUÇÃO

A pecuária é uma atividade econômica essencial, voltada para a criação e comercialização de animais, além de fornecer matéria-prima para a indústria. Em 2024, o Brasil consolidou sua posição como o maior exportador mundial de carne bovina, impulsionado por embarques recordes, que totalizaram 2,89 milhões de toneladas no ano, gerando uma receita de US\$ 12,8 bilhões, um aumento de 22% em comparação a 2023.¹ A pecuária brasileira é dividida em diferentes tipos, como a pecuária leiteira, que tem como principal produto o leite e é bastante forte no estado de Minas Gerais, e a pecuária de corte, relacionada à produção de carne, com destaque para a região Centro-Oeste, onde Mato Grosso lidera o ranking brasileiro. Minas Gerais, conhecido como o maior produtor de leite do país, recebeu recentemente investimentos significativos da Lactalis, maior empresa de lácteos do mundo, que anunciou um aporte de R\$ 250 milhões até 2025 para modernizar e ampliar suas fábricas no estado, reforçando a importância da pecuária leiteira na região.² Já Mato Grosso, que detém o maior rebanho bovino do Brasil, com aproximadamente 31,5 milhões de cabeças de gado, consolidou-se como líder na pecuária de corte, com eventos como o Acrimat em Ação, que promove debates e práticas inovadoras para o setor.³ Essa atividade econômica é fundamental para a sociedade, pois está diretamente ligada à produção de alimentos, como carne, leite, ovos e derivados.

No entanto, a bovinocultura de corte enfrenta desafios significativos, especialmente relacionados ao manejo adequado dos recursos e ao bem-estar animal. O ciclo de vida do gado de corte, desde o nascimento até o abate, tradicionalmente durava cerca de 8 anos. Atualmente, com avanços na pecuária, esse período foi reduzido para aproximadamente 5 a 6 anos, exige um longo período de engorda antes de resultar em lucro.⁴ Esse processo é demorado e custoso, e o produtor só obtém retorno financeiro com a venda do animal, tornando o retorno sobre o investimento mais lento em comparação com a bovinocultura leiteira. Além disso, como destacado por (Michael e Cockram, 2021), o estresse no manejo dos animais pode impactar negativamente a produtividade e o bem-estar do rebanho, agravando os desafios já existentes.

¹ BRASIL bate recorde nas exportações de carne bovina em 2024. ApexBrasil, [2024]. Disponível em: <https://apexbrasil.com.br/br/pt/conteudo/noticias/Brasil-bate-recorde-nas-exportacoes-de-carne-bovina-em-2024.html>. Acesso em: 18 fev. 2025.

² BOUÇAS, Cibelle. Lactalis investe R\$ 250 milhões até 2025 em fábricas em MG. Globo Rural, 2024. Disponível em:

<https://globo.rural.globo.com/pecuaria/leite/noticia/2024/11/lactalis-investe-r-250-milhoes-ate-2025-em-fabricas-em-mg.ghtml>. Acesso em: 18 fev. 2025.

³ COM público recorde, primeira rota da Acrimat encerra com mais de 1.500 participantes. Diário de Cuiabá, [2024]. Disponível em:

<https://www.diariodecuiaba.com.br/economia/com-publico-recorde-primeira-rota-da-acrimat-encerra-com-mais-de-1-500-participantes/701789>. Acesso em: 18 fev. 2025.

⁴ CICLO pecuário do gado de corte: entenda o que é. Dicas Boi Saúde, [2024]. Disponível em:

https://dicas.boisaude.com.br/ciclo-pecuario-do-gado-de-corte/?utm_source=chatgpt.com. Acesso em: 18 fev. 2025.

Nesse contexto, o monitoramento do comportamento dos bovinos surge como uma ferramenta estratégica para otimizar o manejo dos rebanhos e garantir o bem-estar animal. Como destacado por (Marcia del Campo et al., 2024), o bem-estar animal é um componente crítico para a sustentabilidade e a qualidade da produção de carne. Estudos recentes, como o de (Tong, Lei et al., 2024), demonstram que técnicas de rastreamento e monitoramento são eficazes para avaliar o comportamento do rebanho e identificar padrões que podem indicar problemas de saúde ou estresse.

Com base nessas evidências, este trabalho propõe o desenvolvimento de um sistema de monitoramento automatizado baseado em técnicas de aprendizado profundo, com a utilização do modelo YOLO (*You Only Look Once*), proposta por (Redmon et al., 2015), para detectar e classificar atividades comportamentais de bovinos, como beber água, se alimentar, deitar e permanecer em pé, com base em imagens obtidas no ambiente de descanso e confinamento do rebanho. Este estudo adota uma abordagem de Pesquisa com Métodos Mistos, combinando técnicas quantitativas, como o uso do algoritmo aprendizado profundo para análise de imagens e identificação de padrões comportamentais, com uma análise qualitativa dos impactos desses padrões no manejo e bem-estar animal. Essa abordagem permite uma compreensão mais abrangente do problema e a proposição de soluções práticas para a pecuária de corte.

Este trabalho tem como objetivo geral o uso de técnicas de *deep learning* pode contribuir para o monitoramento do comportamento de bovinos em ambiente de confinamento, identificando e classificando os principais comportamentos desses animais. Além disso, busca-se compreender de que forma o monitoramento automatizado pode aprimorar o bem-estar animal e a eficiência produtiva na pecuária de corte, oferecendo informações valiosas para a gestão e otimização desses sistemas.

A solução proposta tem como objetivo específico monitorar continuamente os animais, identificando padrões e irregularidades comportamentais que possam indicar a necessidade de intervenção, visando o bem-estar dos bovinos e o aumento da produtividade. O sistema, voltado para a agricultura de precisão, fornece informações pertinentes para decisões estratégicas, incentivando uma administração mais sustentável e eficiente na pecuária contemporânea.

2 FUNDAMENTAÇÃO TEÓRICA

2.1 Aprendizado Profundo e Visão Computacional

O aprendizado profundo (*deep learning*) consolidou-se como uma das principais abordagens para análise de imagens, sendo amplamente aplicado em problemas de classificação, segmentação e detecção de objetos. Entre as arquiteturas mais utilizadas estão as redes neurais convolucionais (CNNs), projetadas para extrair automaticamente características relevantes das imagens por meio de camadas convolucionais sucessivas (He et al., 2016). A capacidade de aprender representações hierárquicas torna as CNNs particularmente adequadas para lidar com a complexidade visual presente em ambientes reais, como aqueles relacionados ao monitoramento animal.

2.2 YOLO (*You Only Look Once*)

Entre os modelos de detecção de objetos, a arquitetura YOLO, destaca-se por realizar a detecção em tempo real, mantendo boa acurácia. Diferentemente de abordagens tradicionais baseadas em propostas de regiões, o YOLO utiliza uma única rede convolucional para dividir a imagem em grades e prever, simultaneamente, as caixas delimitadoras (*bounding boxes*) e as probabilidades de classe. Essa estratégia confere alta velocidade de inferência e torna o modelo eficiente em cenários que exigem respostas rápidas, como o monitoramento de animais em ambientes de confinamento.

O modelo YOLO foi inicialmente treinado utilizando a base de dados *PASCAL VOC* (EVERINGHAM et al., 2010), composta por 20 classes de objetos comuns em imagens do cotidiano. Posteriormente, as versões mais recentes foram treinadas também na base de dados MS COCO (Lin et al., 2014), que contém 80 classes e um volume significativamente maior de imagens e anotações. Essa evolução permitiu ao YOLO alcançar maior capacidade de generalização e melhor desempenho em diferentes contextos de aplicação.

A aplicabilidade do YOLO em sistemas agropecuários já foi demonstrada em diferentes contextos. (Liu et al., 2021) aplicaram a arquitetura YOLOv4 para monitorar o comportamento de aves em granjas, alcançando resultados satisfatórios na identificação de atividades como alimentação e repouso. Mais recentemente, (Guarnido-López et al., 2024) utilizaram o YOLO para identificar padrões alimentares em bovinos, evidenciando sua utilidade na agricultura de precisão.

2.3 Aprendizado por Transferência

O aprendizado por transferência (*transfer learning*) é uma técnica que consiste em aproveitar pesos de modelos previamente treinados em grandes bases de dados, como ImageNet (Deng et al., 2009) e MS COCO, para acelerar o treinamento em novos problemas. Esse recurso é especialmente vantajoso em situações onde há escassez de dados rotulados, como ocorre com frequência em pesquisas aplicadas na agropecuária. De acordo com (Da Silva et al., 2017), o uso do aprendizado por transferência permite não apenas reduzir o tempo de treinamento, mas também melhorar a capacidade de generalização do modelo em tarefas específicas.

Diversas arquiteturas têm sido utilizadas nesse processo. A AlexNet (Krizhevsky et al., 2012) foi uma das primeiras redes convolucionais profundas a se destacar em competições de visão computacional, servindo como marco inicial para o aprendizado profundo moderno. A ResNet (He et al., 2016) introduziu os blocos residuais, possibilitando o treinamento de redes muito mais profundas sem degradação de desempenho. Já a DDRNet (Hong et al., 2021) se destacou em tarefas de segmentação, combinando eficiência e precisão. Essas arquiteturas, treinadas em grandes bases de dados, são frequentemente utilizadas como ponto de partida em novos problemas, permitindo que modelos aprendam de forma mais rápida e eficaz a partir de conjuntos menores de dados.

2.4 Frameworks de Implementação

Entre as bibliotecas utilizadas para desenvolvimento de modelos de visão computacional, a *Ultralytics*, construída sobre o *PyTorch*, tem ganhado destaque pela praticidade de configuração e suporte nativo à arquitetura YOLO. Essa framework fornece rotinas otimizadas de treinamento, suporte a hardware acelerado e integração simplificada de técnicas como o aprendizado por transferência, permitindo que pesquisadores e profissionais apliquem modelos avançados em diferentes cenários com menor complexidade de implementação.

3 MATERIAL E MÉTODOS

Para o desenvolvimento do sistema de detecção de comportamentos bovinos, foi utilizada a *framework Ultralytics*, por sua praticidade na configuração de hiperparâmetros e suporte nativo a arquiteturas de deep learning.

O modelo escolhido foi o YOLO, devido à sua capacidade de realizar detecção de objetos em tempo real com alto desempenho, característica essencial para cenários de monitoramento contínuo em ambientes de confinamento. A Figura 1 apresenta a

Tabela 1. Distribuição de classes por subconjunto do dataset

Classe	Treinamento (1200 imagens)	Validação (182 imagens)	Teste (122 imagens)	Total Geral (1504 imagens)
Bebendo	90	6	3	99
Comendo	758	97	59	914
Sentado	1166	167	84	1417
Em pé	1214	212	179	1605
Total Objetos	3228	482	325	4035

3.3 Métricas de Avaliação

A avaliação do desempenho do modelo de detecção de comportamentos bovinos foi realizada com base em métricas amplamente utilizadas na área de detecção de objetos, proporcionando uma visão abrangente da qualidade das previsões e da capacidade preditiva do modelo. Antes da apresentação das equações, é importante definir os conceitos fundamentais que compõem essas métricas:

- TP (Verdadeiro Positivo): Quando o modelo detecta corretamente um objeto da classe de interesse.
- TN (Verdadeiro Negativo): Quando o modelo identifica corretamente que não há objeto da classe de interesse.
- FP (Falso Positivo): Quando o modelo detecta incorretamente um objeto onde não existe.
- FN (Falso Negativo): Quando o modelo falha em detectar um objeto que realmente está presente.

Com base nesses conceitos, as principais métricas utilizadas neste trabalho são:

- Acurácia (equação 1) – mede a proporção de predições corretas (positivas e negativas) em relação ao total de amostras avaliadas:

$$Acurácia = \frac{TP + TN}{TP + TN + FP + FN} \quad (1)$$

- Recall (equação 2): também conhecido como sensibilidade, avalia a proporção de objetos corretamente detectados entre todos os objetos reais presentes na imagem:

$$Recall = \frac{TP}{TP + FN} \quad (2)$$

- Precisão (equação 3): mede a proporção de detecções corretas entre todas as detecções realizadas pelo modelo:

$$Precisão = \frac{TP}{TP + FP} \quad (3)$$

- F1-score (equação 4): representa a média harmônica entre precisão e recall, sendo especialmente útil em cenários com classes desbalanceadas:

$$F1 = 2 \cdot \frac{Precisão \cdot Recall}{Precisão + Recall} \quad (4)$$

Essas métricas fornecem uma análise equilibrada do desempenho do modelo, considerando sua capacidade de detectar corretamente os objetos (recall), a confiabilidade dessas detecções (precisão) e a taxa geral de acertos (acurácia). O F1-score, por sua vez, complementa essa análise ao equilibrar os efeitos da precisão e do recall.

Além da avaliação por métricas clássicas de desempenho, durante os experimentos foi identificado um desafio recorrente em tarefas de detecção de objetos: a oclusão entre instâncias de uma mesma classe. Esse problema também foi reportado por (Da Silva et al., 2017) em seu estudo sobre o algoritmo *Traffic Sign Recognition* (TSR).

No presente trabalho, a oclusão ocorre quando dois ou mais bovinos aparecem parcialmente sobrepostos na imagem, dificultando a identificação individual de seus comportamentos. Para mitigar esse efeito e garantir maior precisão na contagem das detecções, foi adotada uma estratégia de filtragem baseada na confiança das predições, conforme descrito a seguir.

A Figura 2 ilustra um exemplo desse tipo de situação, em que há sobreposição entre dois animais, dificultando a segmentação clara dos comportamentos individuais. Nesses cenários, o modelo pode realizar múltiplas detecções para um mesmo animal ou omitir completamente uma instância, o que compromete a precisão global do sistema. A filtragem por confiança mostrou-se fundamental para priorizar apenas as predições com maior probabilidade de acerto, reduzindo os impactos negativos causados por oclusões.

Figura 2. Exemplo de oclusão entre bovinos e aplicação da filtragem por confiança. A imagem mostra dois bovinos parcialmente sobrepostos, gerando múltiplas detecções. A filtragem top-K baseada na confiança permite eliminar predições de baixa confiabilidade, mantendo apenas as mais precisas.



Para lidar com o problema de oclusão, uma das principais causas de múltiplas detecções redundantes ou incorretas em tarefas de detecção de objetos foi implementada uma estratégia de filtragem baseada na confiança das predições. A abordagem consistiu em obter todas as detecções produzidas pelo modelo, juntamente com os respectivos escores de confiança. Essas detecções foram representadas por pares contendo a classe prevista e sua confiança associada.

Quando o número de detecções excedia a quantidade esperada de objetos reais (*ground truth*) na imagem, o algoritmo aplicava uma ordenação decrescente com base na confiança e mantinha apenas as K detecções com maior probabilidade, onde K

correspondia ao número de objetos verdadeiros. Essa técnica visa reduzir o impacto de detecções espúrias ou duplicadas, geralmente ocasionadas por objetos parcialmente visíveis ou sobrepostos (ocluídos), garantindo que apenas as predições mais confiáveis fossem consideradas na avaliação. Essa abordagem é especialmente útil para ambientes com múltiplos indivíduos da mesma classe, como é o caso do comportamento de bovinos em grupo, em que oclusões são frequentes.

3.4 Validação Cruzada


Para avaliar de forma mais robusta a capacidade de generalização do modelo, foi aplicada a técnica de *K-Fold Cross-Validation* (Kohavi, 1995). O procedimento consistiu em unir os conjuntos de treinamento e validação, dividindo-os em $K = 5$ *folds* (partições) estratificados. Em cada iteração, quatro *folds* foram utilizados para treinamento e o *fold* restante para validação, repetindo o processo até que todos os *folds* fossem usados como validação.

Ao final, foram obtidas as métricas de cada *fold* (Precisão e *Recall*), e então calculadas as médias e desvios padrão, fornecendo uma análise mais estável do desempenho do modelo em diferentes subconjuntos dos dados. O conjunto de teste foi mantido separado e não participou do processo de *cross-validation*, sendo reservado para uma avaliação final do modelo selecionado.

4 RESULTADOS

A avaliação do desempenho do modelo foi realizada com base no conjunto de teste, composto por 122 imagens e 325 objetos anotados. Para essa etapa, utilizou-se a matriz de confusão na Figura 3 e o relatório de classificação, a fim de mensurar a performance do modelo em relação às quatro classes de comportamento: Bebendo, Comendo, Sentado e Em pé.

Figura 3. Matriz de Confusão do Modelo no Conjunto de Teste



A acurácia geral obtida foi de 97%, evidenciando um excelente desempenho do modelo na maioria das categorias. As métricas detalhadas por classe são apresentadas na Tabela 2.

Tabela 2. Relatório de Classificação por Classe

Classe	Precisão	Revocação (Recall)	F1-Score
Bebendo	0.29	0.67	0.40
Comendo	0.98	0.98	0.98
Sentado	1.00	1.00	1.00
Em pé	0.99	0.99	0.99

A classe "Sentado" apresentou desempenho perfeito em todas as métricas, enquanto as classes "Em pé" e "Comendo" também atingiram altos valores de precisão e recall, indicando uma ótima capacidade de generalização do modelo nesses comportamentos.

Em contrapartida, a classe "Bebendo" apresentou desempenho inferior, o que está diretamente relacionado ao desbalanceamento da base de dados. Conforme mostrado na Tabela 1 (seção anterior), essa classe tem apenas 3 exemplos no conjunto de teste. Mesmo diante dessa limitação, o modelo conseguiu identificar corretamente uma parte dessas instâncias, alcançando um *recall* de 67%, o que demonstra sua sensibilidade, ainda que com baixa precisão. Essa limitação reforça a necessidade de estratégias futuras como *data augmentation* direcionado. A Figura 3 apresenta a matriz de confusão resultante, destacando a predominância de acertos nas classes majoritárias e os principais pontos de confusão, notadamente entre a classe "Bebendo" e outras categorias como "Em pé".

Como pode ser observado na Figura 3, a maioria das predições incorretas está concentrada na classe "Bebendo", que foi frequentemente confundida com outras categorias, principalmente "Em pé". Esse comportamento pode ser atribuído à semelhança visual entre as posturas e ao número reduzido de exemplos dessa classe no conjunto de dados, o que compromete a capacidade do modelo de aprender representações robustas para esse comportamento. Apesar disso, o modelo demonstrou alta efetividade nas classes majoritárias, validando sua utilidade prática para aplicações reais de monitoramento de comportamento bovino.

Além disso, a figura 4 ilustra de forma qualitativa o efeito da filtragem por confiança aplicada às detecções do modelo. À esquerda observa-se a presença de predições com oclusão e caixas sobrepostas, enquanto à direita a filtragem remove detecções de baixa probabilidade, resultando em uma saída mais limpa e consistente. Esse processo contribui para a redução de falsos positivos e melhora a interpretabilidade das detecções.

Figura 4. Comparação entre detecção com oclusão (à esquerda) e resultado após a aplicação da filtragem por confiança (à direita).



5 CONCLUSÃO

Este trabalho propôs e avaliou um modelo para a detecção e classificação de comportamentos bovinos com base em imagens, utilizando técnicas de visão computacional e aprendizado profundo. A abordagem adotada demonstrou resultados promissores, com uma acurácia geral de 97% no conjunto de teste, e desempenho quase perfeito nas classes "Comendo", "Sentado" e "Em pé". Uma das contribuições relevantes foi a aplicação de uma estratégia de filtragem por confiança para mitigar os efeitos da oclusão entre objetos da mesma classe, um desafio recorrente em ambientes reais de monitoramento de animais. Essa técnica demonstrou-se eficaz para selecionar apenas as detecções mais confiáveis, aumentando a precisão geral das previsões.

Apesar dos bons resultados, foi identificado um desempenho inferior na classe "Bebendo", consequência do forte desbalanceamento da base de dados, com uma representação muito limitada dessa categoria. Ainda assim, o modelo conseguiu identificar corretamente parte dos poucos exemplos disponíveis, o que indica seu potencial mesmo sob restrições de dados.

De modo geral, o modelo desenvolvido demonstrou viabilidade prática para o monitoramento automatizado de bovinos, contribuindo para o avanço de soluções tecnológicas na área da agropecuária. A detecção automática de comportamentos pode oferecer apoio importante para o bem-estar animal, gestão de rebanhos e identificação precoce de anormalidades, promovendo uma pecuária mais eficiente e sustentável.

Como trabalhos futuros, sugere-se o uso de técnicas de aumento de dados (*data augmentation*) para balancear melhor as classes. Além disso, a integração do modelo em dispositivos de baixo consumo, como *Raspberry Pi* com aceleradores de inferência, permitirá a validação do sistema em campo, aproximando ainda mais a solução da sua aplicação real.

6 AGRADECIMENTO

Gostaria de expressar meu sincero agradecimento ao meu orientador, pelo apoio incansável, orientação técnica precisa e incentivo constante durante todo o desenvolvimento deste trabalho. Sua expertise, paciência e dedicação foram fundamentais para a concretização deste projeto, enriquecendo minha formação acadêmica e profissional. Agradeço também a mim mesmo pelo esforço e perseverança

ao longo dessa jornada, que me permitiram superar desafios e alcançar os resultados apresentados. Este trabalho é fruto da colaboração e confiança mútua, e sou grato por ter contado com uma orientação tão comprometida e inspiradora.

7 REFERÊNCIAS

COW DETECTION IDENTIFIER. *Cow Behavior Tracking Dataset*, 2024. Disponível em: <https://universe.roboflow.com/cow-detection-identifier/cow-behavior-tracking>. Acesso em: 17 fev. 2025.

DA SILVA, D. L.; SEIJAS, L. M.; BASTOS-FILHO, C. J. A. Artificial Bee Colony Optimization for Feature Selection of Traffic Sign Recognition. *International Journal of Swarm Intelligence Research*, v. 8, n. 2, p. 50–66, abr. 2017.

DENG, Jia et al. ImageNet: A large-scale hierarchical image database. In: *IEEE Conference on Computer Vision and Pattern Recognition*, 2009, Miami, FL. Anais [...]. IEEE, 2009. p. 248–255. DOI: 10.1109/CVPR.2009.5206848.

EVERINGHAM, M. et al. The PASCAL Visual Object Classes (VOC) Challenge. *International Journal of Computer Vision*, v. 88, n. 2, p. 303–338, 2010. DOI: <https://doi.org/10.1007/s11263-009-0275-4>.

GUARNIDO-LOPEZ, P.; RAMIREZ-AGUDELO, J. F.; DENIMAL, E.; BENAUDA, M. Programming and Setting Up the Object Detection Algorithm YOLO to Determine Feeding Activities of Beef Cattle: A Comparison between YOLOv8m and YOLOv10m. *Animals*, v. 14, n. 19, p. 2821, 2024. Disponível em: <https://doi.org/10.3390/ani14192821>.

HE, K.; ZHANG, X.; REN, S.; SUN, J. Deep residual learning for image recognition. In: *IEEE Conference on Computer Vision and Pattern Recognition*, 2016, Las Vegas. Anais [...]. IEEE, 2016. p. 770–778.

HONG, Y.; GAO, L.; CHEN, J.; SHI, M. Deep dual-resolution networks for real-time and accurate semantic segmentation of road scenes. *arXiv preprint*, arXiv:2101.06085, 2021. Disponível em: <https://arxiv.org/abs/2101.06085>.

KRIZHEVSKY, A.; SUTSKEVER, I.; HINTON, G. E. ImageNet classification with deep convolutional neural networks. *Advances in Neural Information Processing Systems*, v. 25, p. 1097–1105, 2012.

KOHAVI, R. *A study of cross-validation and bootstrap for accuracy estimation and model selection*. In: INTERNATIONAL JOINT CONFERENCE ON ARTIFICIAL INTELLIGENCE. Proceedings... San Mateo: Morgan Kaufmann, 1995. p. 1137–1145.

LIN, Tsung-Yi et al. Microsoft COCO: Common Objects in Context. In: *European Conference on Computer Vision*, 2014, Zurich. Anais [...]. Cham: Springer, 2014. p. 740–755. DOI: 10.1007/978-3-319-10602-1_48.

LIU, Kang; WANG, Shengli; WU, Chao. Application of YOLOv4 and DeepSort in real-time poultry behavior detection and tracking. *Computers and Electronics in Agriculture*, v. 186, p. 106171, 2021. Disponível em: <https://doi.org/10.1016/j.compag.2021.106171>.

MARCIA DEL CAMPO, M.; MONTOSI, F.; SOARES DE LIMA, J. M.; BRITO, G. Future cattle production: Animal welfare as a critical component of sustainability and beef

quality, a South American perspective. *Meat Science*, v. 219, p. 109672, 2024.
Disponível em: <https://doi.org/10.1016/j.meatsci.2024.109672>.

MICHAEL, S.; COCKRAM, M. Cattle handling stress and transportation. In: GRANDIN, T. (org.). *Livestock Handling and Transport*. 5. ed. Cambridge: Elsevier, 2024. p. 666–674. DOI: 10.1016/B978-0-323-85125-1.00033-8.

REDMON, J.; DIVVALA, S.; GIRSHICK, R.; FARHADI, A. You Only Look Once: Unified, real-time object detection. *arXiv preprint*, 2015. Disponível em: <https://arxiv.org/abs/1506.02640>.

TONG, L.; FANG, J.; WANG, X.; ZHAO, Y. Research on Cattle Behavior Recognition and Multi-Object Tracking Algorithm Based on YOLO-BoT. *Animals*, v. 14, n. 20, p. 2993, 2024. Disponível em: <https://doi.org/10.3390/ani14202993>.

SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO
BIBLIOTECA DEPOSITÁRIA – CAMPUS Palmares

**TERMO DE AUTORIZAÇÃO PARA DISPONIBILIDADE DE LIVRO / CAPÍTULO DE LIVRO / ARTIGO
OU REA NO REPOSITÓRIO INSTITUCIONAL IFPE**

Na qualidade de titular dos direitos de autor da publicação, autorizo ao Repositório Institucional do Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco (RIIFPE) a disponibilizar, através do site <https://repositorio.ifpe.edu.br/xmlui/>, sem ressarcimento dos direitos autorais, de acordo com a Lei n. 9.610/98, o texto integral da obra abaixo citada, a título de divulgação e de preservação digital da produção científica brasileira, a partir desta data.

Identificação:

Autor*	Kauã Gabriel Silva de Lima
E:mail	Kaua32475@gmail.com
Orcid	https://orcid.org/0009-0002-5458-792X
Link Lattes	http://lattes.cnpq.br/2662274528173548
Título	MONITORAMENTO DO COMPORTAMENTO DE BOVINOS PARA APOIO A GRANDES FAZENDAS E MANEJO DE REBANHOS
Data de defesa	30/07/2025
ISBN	
DOI	
ODS Agenda 2030 (quando cabível)	

*Preenchimento individual, em caso de mais de um autor.

LICENÇA DE DIREITO AUTORAL

Na qualidade de titular dos direitos de autor do conteúdo supracitado, autorizo o Instituto Federal de Educação, Ciência e Tecnologia de Pernambuco a disponibilizar a obra, gratuitamente, de acordo com a licença pública *Creative Commons*, Licença 4.0 *Unported* por mim declarada sob as seguintes condições:

Permitir uso comercial da obra? (x) Sim () Não

Permitir modificações em sua obra?


() Sim

(x) Sim, contanto que outros compartilhem pela mesma licença

() Não

A obra continua protegida por direito autoral e/ou por outras leis aplicáveis, respeitando inclusive o contrato celebrado entre a editora ou periódico que veicula a mesma. Qualquer uso da obra que não o autorizado sob esta licença ou pela legislação autoral é proibido.

Documento assinado digitalmente

 **KAUA GABRIEL SILVA DE LIMA**
Data: 20/08/2025 16:20:06-0300
Verifique em <https://validar.iti.gov.br>

Assinatura do Autor

Data de autorização. 20 / agosto / 2025



SERVIÇO PÚBLICO FEDERAL
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DE PERNAMBUCO
BIBLIOTECA DEPOSITÁRIA – CAMPUS PALMARES

TERMO DE RESPONSABILIDADE DO ORIENTADOR E AUTORIZAÇÃO PARA PUBLICAÇÃO DA PRODUÇÃO INTELECTUAL NO REPOSITÓRIO INSTITUCIONAL RI-IFPE

Eu, Diogo Lopes da Silva, CPF: 048.364.234-73, ORCID: 0009-0004-7649-1448, link lattes: 9276635214661347, orientador do Trabalho de Conclusão de Curso, intitulado: MONITORAMENTO DO COMPORTAMENTO DE BOVINOS PARA APOIO A GRANDES FAZENDAS E MANEJO DE REBANHOS realizado pelo aluno(a) Kauã Gabriel Silva de Lima, Matrícula nº 20222ADS-PM0105, Curso: Tecnólogo em Análise e Desenvolvimento de Sistemas, autorizo o depósito obrigatório, na Biblioteca Campus Palmares, da versão final, no modelo de: (X) artigo () monografia () dissertação ().

INFORMAÇÕES DA BANCA			
NOME	CPF	ORCID	LINK LATTES
Rodrigo César Lira da Silva	082.015.4 04- 09	https://orcid.org/0000-0001-6089-6214	https://lattes.cnpq.br/2442224050349612
Tiago Pessoa Ferreira de Lima	059.602.3 04- 96	https://orcid.org/0000-0002-1148-4288	https://lattes.cnpq.br/4861396173974431

Documento assinado digitalmente



DIOGO LOPES DA SILVA
Data: 19/01/2026 17:51:15-0300
Verifique em <https://validar.iti.gov.br>

Professor orientador