

**AVANÇOS E MÉTODOS NA IDENTIFICAÇÃO INDIVIDUAL DE VACAS LEITEIRAS:
UMA REVISÃO DE LITERATURA**

**ADVANCES AND METHODS IN THE INDIVIDUAL IDENTIFICATION OF DAIRY
COWS: A LITERATURE REVIEW**

**AVANCES Y MÉTODOS EN LA IDENTIFICACIÓN INDIVIDUAL DE VACAS LECHERAS:
UNA REVISIÓN DE LA LITERATURA**

 <https://doi.org/10.56238/rcsv15n12-002>

Data de submissão: 12/11/2025

Data de aprovação: 12/12/2025

Lúcia Cardoso Moron Rodrigues

Mestranda pelo Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas
Instituição: Universidade de São Paulo, Escola Superior de Agricultura “Luiz de Queiroz”
(USP/ESALQ)

E-mail: moronr@usp.br
Orcid: <https://orcid.org/0009-0001-1097-5341>

Magno do Nascimento Amorim

Professor Mestre do Departamento de Engenharia Agrícola
Instituição: Instituto Federal Goiano (IFGoiano)
E-mail: magno.amorim@ifgoiano.edu.br
Orcid: <https://orcid.org/0000-0003-0332-2905>

Késia Oliveira da Silva-Miranda

Professora Doutora pelo Programa de Pós-Graduação em Engenharia de Sistemas Agrícolas
Instituição: Universidade de São Paulo, Escola Superior de Agricultura “Luiz de Queiroz”
(USP/ESALQ)

Orcid: <https://orcid.org/0000-0001-5143-0789>

RESUMO

A identificação individual é uma ferramenta essencial para a zootecnia de precisão, permitindo a automação em tempo real do monitoramento da saúde, produtividade e rastreabilidade dos rebanhos. Essa prática otimiza processos produtivos, aumenta a eficiência e promove a sustentabilidade da produção. Nesse contexto, esta revisão bibliográfica teve como objetivo analisar os avanços e métodos utilizados na identificação individual de vacas leiteiras, com ênfase na pecuária leiteira de precisão. Foram revisados estudos que abordam tecnologias de aprendizado profundo e aprendizado de máquina, destacando sua contribuição para a melhoria da precisão da identificação, mesmo em condições de campo desafiadoras. Técnicas de visão computacional têm aprimorado a eficiência do processo, embora enfrentem desafios relacionados à variabilidade das condições ambientais e à implementação em larga escala. O uso de drones e imagens multiangulares amplia as possibilidades de monitoramento, evidenciando o potencial dessas tecnologias para atender às demandas de escalabilidade e precisão. No Brasil, onde a produção leiteira é majoritariamente composta por pequenos e médios produtores, a adoção de tecnologias acessíveis torna-se fundamental para elevar a eficiência e a competitividade do setor. Os avanços tecnológicos também favorecem a rastreabilidade e a saúde animal, contribuindo para práticas mais sustentáveis. Conclui-se que a integração dessas ferramentas na realidade da pecuária nacional exige soluções adaptadas ao contexto socioeconômico dos produtores, sendo necessário o desenvolvimento de pesquisas que conciliem inovação tecnológica com viabilidade prática e econômica.

Palavras-chave: Visão Computacional. Pecuária de Precisão. Rastreabilidade. Tecnologias de Monitoramento.

ABSTRACT

Individual identification is a fundamental tool for precision livestock farming, enabling real-time automated monitoring of health, productivity, and herd traceability. This practice optimizes production processes, enhances efficiency, and promotes sustainable production. In this context, this literature review aimed to analyze advances and methods used for the individual identification of dairy cows, with a focus on precision dairy farming. We reviewed studies on deep learning and machine learning technologies, highlighting their role in improving identification accuracy—even under challenging field conditions. Computer vision techniques have increased process efficiency, though challenges persist regarding environmental variability and large-scale implementation. The use of drones and multi-angle imaging expands monitoring possibilities, demonstrating the potential of these technologies to meet scalability and precision demands. In Brazil, where dairy production is predominantly carried out by small and mid-sized farmers, adopting cost-effective technologies is critical to enhancing sector efficiency and competitiveness. Technological advancements also support traceability and animal health, fostering more sustainable practices. We conclude that integrating these tools into national livestock operations requires solutions tailored to the producers' socioeconomic context, necessitating further research to balance technological innovation with practical and economic feasibility.

Keywords: Computer Vision. Precision Livestock Farming. Traceability. Monitoring Technologies.

RESUMEN

La identificación individual es una herramienta esencial para la zootecnia de precisión, ya que permite la automatización en tiempo real del control de la salud, la productividad y la trazabilidad de los rebaños. Esta práctica optimiza los procesos productivos, aumenta la eficiencia y promueve la sostenibilidad de la producción. En este contexto, el objetivo de esta revisión bibliográfica fue analizar los avances y métodos utilizados en la identificación individual de vacas lecheras, con énfasis en la ganadería lechera de precisión. Se revisaron estudios que abordan las tecnologías de aprendizaje profundo y aprendizaje automático, destacando su contribución a la mejora de la precisión de la identificación, incluso en condiciones de campo difíciles. Las técnicas de visión artificial han mejorado la eficiencia del proceso, aunque se enfrentan a retos relacionados con la variabilidad de las condiciones ambientales y la implementación a gran escala. El uso de drones e imágenes multiangulares amplía las posibilidades de monitorización, poniendo de manifiesto el potencial de estas tecnologías para satisfacer las demandas de escalabilidad y precisión. En Brasil, donde la producción lechera está compuesta principalmente por pequeños y medianos productores, la adopción de tecnologías accesibles es fundamental para aumentar la eficiencia y la competitividad del sector. Los avances tecnológicos también favorecen la trazabilidad y la salud animal, contribuyendo a prácticas más sostenibles. Se concluye que la integración de estas herramientas en la realidad ganadera nacional exige soluciones adaptadas al contexto socioeconómico de los productores, siendo necesario desarrollar investigaciones que concilien la innovación tecnológica con la viabilidad práctica y económica.

Palabras clave: Visión Computacional. Ganadería de Precisión. Trazabilidad. Tecnologías de Monitoreo.

1 INTRODUÇÃO

A produção de leite é uma atividade de grande relevância econômica em âmbito mundial, figurando entre as principais commodities agropecuárias, especialmente em países como o Brasil. Segundo o Departamento de Agricultura dos Estados Unidos (USDA, 2023), o país ocupa a terceira posição entre os maiores produtores globais, com uma estimativa de 25 milhões de toneladas para 2024. O setor é essencial para a segurança alimentar, geração de empregos e estabilidade econômica, estando presente em 98% dos municípios brasileiros e empregando cerca de 4 milhões de pessoas, majoritariamente pequenos e médios produtores.

Nos últimos anos, a pecuária leiteira brasileira tem incorporado inovações tecnológicas que aumentam a competitividade entre os produtores (Embrapa, 2024). Paralelamente, crescem as exigências dos consumidores por alimentos produzidos de forma sustentável e com atenção ao bem-estar animal (Turco *et al.*, 2019). De acordo com o Ministério da Agricultura e Pecuária (MAPA, 2024), até 2030, apenas os produtores mais eficientes e tecnificados devem permanecer na atividade, com destaque para aqueles que adotarem tecnologias, aperfeiçoarem a gestão e aumentarem a eficiência técnico-econômica — enquanto pequenos laticínios tendem a perder espaço (Embrapa, 2024).

Nesse contexto, destaca-se a Pecuária Leiteira de Precisão (PLP), definida como uma abordagem gerencial que utiliza tecnologias da informação e comunicação com o objetivo de otimizar, de forma econômica, social e ambiental, o desempenho das propriedades leiteiras (Pereira *et al.*, 2015). A PLP permite o monitoramento contínuo da saúde, comportamento, crescimento e produtividade dos animais, bem como o controle ambiental e a mitigação de emissões poluentes (Tullo *et al.*, 2019).

Entre os pilares dessa abordagem está a identificação automática dos animais, que substitui métodos invasivos, como a marcação auricular, por tecnologias que aumentam a precisão das informações, reduzem custos operacionais e promovem o bem-estar animal e a rastreabilidade (Xu *et al.*, 2024; Lovarelli *et al.*, 2019).

Soluções baseadas em visão computacional, especialmente aquelas que utilizam aprendizado de máquina e redes neurais profundas (*deep learning*), vêm sendo amplamente exploradas para o reconhecimento e mensuração de características fisiológicas e comportamentais a partir de imagens. Tais aplicações incluem a identificação individual, análise de comportamento, avaliação de carcaças, inspeção pós-morte e previsão de crescimento (Kunze *et al.*, 2018; Steeneveld *et al.*, 2015; Nolêto *et al.*, 2023).

Diante desse cenário, o presente trabalho tem como objetivo revisar os principais avanços e métodos aplicados à identificação individual de vacas leiteiras no contexto da pecuária de precisão, com ênfase nas tecnologias de visão computacional e inteligência artificial.

2 MATERIAIS E MÉTODOS

A pesquisa para esta revisão bibliográfica foi conduzida com base em artigos científicos e publicações acadêmicas provenientes de universidades e instituições de pesquisa de reconhecimento internacional. O levantamento foi realizado por meio das plataformas Google Acadêmico, Scopus e ScienceDirect. Inicialmente, empregaram-se os descritores “*individual AND identification AND animals AND deep AND learning*” para uma busca ampla. Em seguida, visando uma maior especificidade, utilizou-se a combinação “*individual AND identification AND cows AND deep AND learning*”. Os critérios de inclusão adotados foram: aderência ao tema, disponibilidade do texto completo e aplicação de novas técnicas de captura de imagem e/ou uso de softwares inovadores para identificação individual.

Durante a triagem inicial, observou-se que os termos utilizados não abarcavam integralmente os estudos mais relevantes ao escopo da pesquisa. Para ampliar a abrangência e a profundidade da revisão, foram realizadas buscas complementares orientadas por tópicos previamente definidos. Além disso, aplicou-se a estratégia de referência cruzada, a qual consistiu na análise das listas bibliográficas dos artigos selecionados, a fim de identificar novas fontes relevantes. Essa abordagem foi complementada por buscas direcionadas a autores frequentemente citados ou reconhecidos por sua contribuição científica no tema, permitindo identificar metodologias específicas, tendências emergentes e inovações tecnológicas significativas.

Os dados coletados evidenciam o crescimento expressivo e recente da aplicação de tecnologias baseadas em visão computacional e aprendizado profundo na identificação individual de animais. Esse avanço destaca a relevância do tema para a evolução da pecuária de precisão, especialmente na bovinocultura leiteira, contribuindo para o aprimoramento do bem-estar animal, da rastreabilidade e da eficiência produtiva. Esses achados reforçam o potencial desse campo como área estratégica para futuras investigações científicas e aplicações práticas no setor agropecuário.

3 REVISÃO DE LITERATURA

3.1 PANORAMA DA PRODUÇÃO DE LEITE NO BRASIL

O Brasil ocupa atualmente a terceira posição no ranking mundial de produção de leite, com uma estimativa de 25 milhões de toneladas para o ano de 2024, representando um crescimento de 1,2% em relação ao ano anterior (USDA, 2023). Esse desempenho consolida o país como um dos principais atores no setor global de lácteos, destacando sua relevância na economia internacional e seu papel estratégico na segurança alimentar.

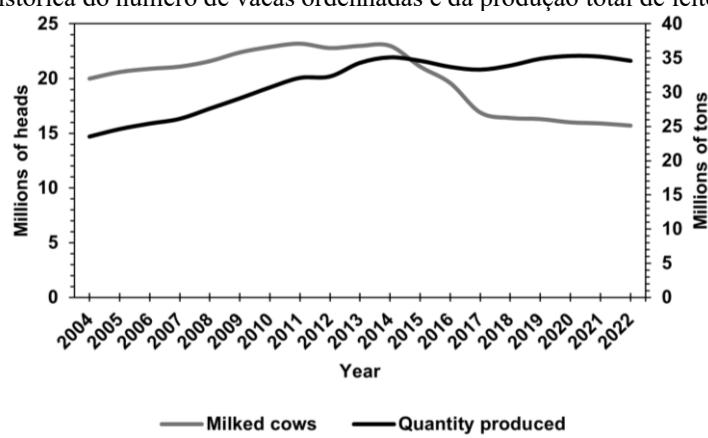
De acordo com o Centro de Inteligência do Leite (2024), o setor leiteiro brasileiro tem apresentado um desempenho expressivo nas exportações de leite e derivados, registrando um aumento

de 24,3% no período de janeiro a agosto de 2024 em comparação com o mesmo período de 2023. No mercado interno, o preço do leite apresentou valorização em agosto, impulsionado pela redução da oferta nas regiões Sudeste e Centro-Oeste, o que resultou em uma relação de troca mais favorável para os produtores.

Além disso, a demanda por lácteos tem sido impulsionada por um ambiente econômico mais estável, com destaque para o controle da inflação, o aumento da massa salarial e a ampliação do acesso ao crédito. Esses fatores têm favorecido o crescimento contínuo do consumo de produtos lácteos pelas famílias brasileiras nos últimos dois anos.

A produção nacional de leite também tem evoluído de forma consistente ao longo do tempo. A Figura 1 apresenta uma análise histórica do número de vacas ordenhadas e da produção total de leite entre os anos de 2004 e 2022, com base em dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2024). Os dados revelam uma tendência de crescimento sustentado da produção, reflexo do aumento da produtividade e da adoção de práticas mais tecnificadas nas propriedades leiteiras.

Figura 1- Análise histórica do número de vacas ordenhadas e da produção total de leite entre 2004 e 2022.



Fonte: Adaptado de Instituto Brasileiro de Geografia e Estatística (IBGE, 2024).

A partir de 2015, observou-se um aumento expressivo na produtividade da pecuária leiteira brasileira. Embora tenha havido uma redução no número de vacas ordenhadas, a produção total de leite continuou a crescer, indicando ganhos significativos de eficiência. Esse avanço está diretamente relacionado à modernização do setor, com destaque para a adoção de tecnologias de manejo, melhorias na nutrição e saúde animal, e a implementação de sistemas de automação e monitoramento, que têm permitido um controle mais preciso do rebanho e de suas necessidades (Barkema *et al.*, 2015).

A Figura 2 ilustra a distribuição geográfica da produção de leite no Brasil em 2022, conforme dados do Instituto Brasileiro de Geografia e Estatística (IBGE, 2024). A Região Sudeste, com destaque para os estados de Minas Gerais e São Paulo, é responsável por aproximadamente 40% da produção nacional, seguida pela Região Sul, que contribui com cerca de 30%. Esses territórios se beneficiam de

uma infraestrutura consolidada, maior acesso a tecnologias e proximidade com centros consumidores estratégicos, fatores que favorecem a competitividade e o desenvolvimento do setor.

Em contrapartida, as regiões Norte e Nordeste ainda enfrentam desafios estruturais importantes, como limitações no acesso a tecnologias de precisão, assistência técnica e infraestrutura logística, o que impacta diretamente a produtividade (Silvi *et al.*, 2021). Apesar dessas desigualdades, todas as regiões brasileiras desempenham um papel relevante na cadeia produtiva do leite, contribuindo para a segurança alimentar e para o fortalecimento das economias regionais.

Figura 2- Distribuição geográfica da produção de leite no Brasil em 2022.

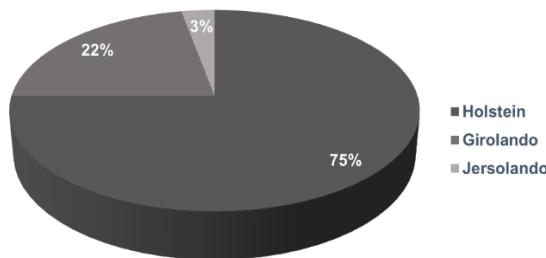


Adaptado de Instituto Brasileiro de Geografia e Estatística (IBGE, 2024).

A raça Holandesa, com destaque para a variedade Holstein-Frísia, é predominante nas grandes propriedades leiteiras brasileiras. Essa variedade é caracterizada pela pelagem branca com manchas pretas bem definidas, enquanto outras linhagens da mesma raça, como Mosa, Reno e Yssel, apresentam pelagem vermelha e branca. A raça Holandesa é amplamente reconhecida por seu elevado potencial produtivo e por sua boa adaptação a sistemas de produção intensivos, sendo uma das mais utilizadas na pecuária leiteira nacional, inclusive em regiões de clima tropical (Augusto, 2023).

A Figura 3 ilustra a predominância da raça Holandesa nas 100 maiores fazendas leiteiras do Brasil, seguida pela raça Girolando, que tem ganhado relevância devido à sua rusticidade, resistência ao estresse térmico e boa adaptação a ambientes de clima quente e seco, característicos das regiões Centro-Oeste e Nordeste (USDA, 2023). Os dados também indicam uma tendência de diversificação genética nos rebanhos, com crescimento expressivo da participação das raças Girolando (22%) e Jersolando (3%), refletindo esforços dos produtores em equilibrar produtividade com adaptabilidade ao clima.

Figura 3- Distribuição das principais raças leiteiras nas 100 maiores fazendas de leite do Brasil.



Fonte: Adaptado de Departamento de Agricultura dos Estados Unidos (USDA, 2023).

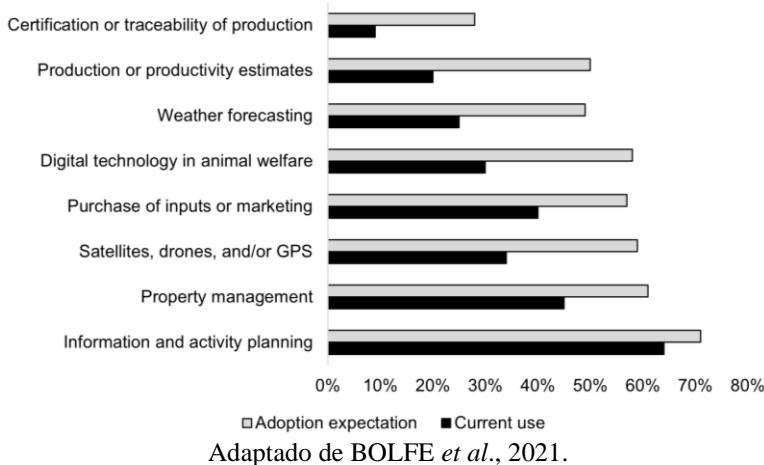
4 PERFIL DO PRODUTOR NO BRASIL

A análise do perfil dos produtores brasileiros é essencial para compreender os fatores que influenciam a adoção e os desafios associados à implementação da pecuária de precisão. Dentre esses fatores, destaca-se a infraestrutura das propriedades rurais, que desempenha papel crucial na promoção do bem-estar animal, garantindo condições adequadas de conforto, segurança e desenvolvimento, com impactos diretos sobre a produtividade e a sustentabilidade da atividade pecuária (Wu *et al.*, 2019).

Além disso, o sucesso na implementação de tecnologias de precisão depende da integração entre infraestrutura física, capacitação técnica dos produtores e sistemas de informação bem estruturados (Tzanidakis *et al.*, 2021). Entretanto, persistem obstáculos significativos, sobretudo relacionados à conectividade. A limitação no acesso à internet em áreas rurais dificulta a utilização de soluções digitais avançadas, comprometendo o funcionamento de sistemas automatizados e a eficiência da gestão produtiva (Moreira *et al.*, 2024).

Nesse cenário, pesquisas de campo com produtores rurais contribuem para identificar padrões de adoção tecnológica, barreiras percebidas e o nível de preparo técnico do setor. Entre abril e junho de 2020, a Embrapa, em parceria com o Serviço Brasileiro de Apoio às Micro e Pequenas Empresas (Sebrae) e o Instituto Nacional de Pesquisas Espaciais (INPE), realizou um levantamento nacional com 335 pecuaristas. Os resultados revelaram que 82% dos participantes já utilizavam alguma ferramenta digital, indicando uma tendência crescente de digitalização no campo, conforme ilustrado na Figura 4.

Figura 4- Principais tecnologias adotadas na pecuária entre abril e junho de 2020.

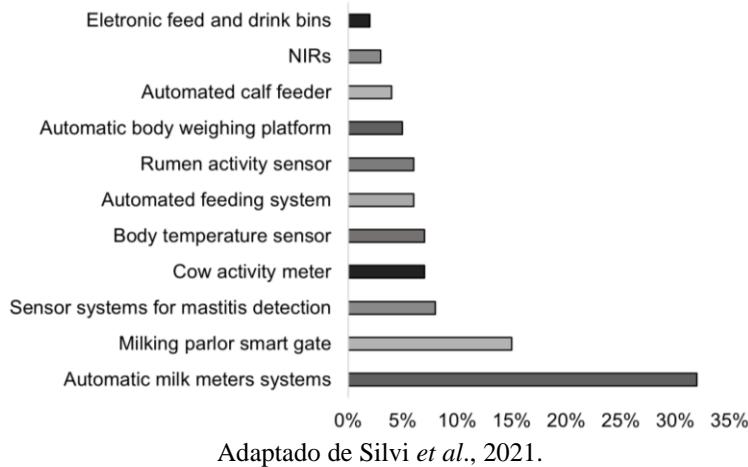
Adaptado de BOLFE *et al.*, 2021.

Os dados demonstram que as tecnologias digitais têm sido aplicadas em diversas etapas da cadeia produtiva do leite, desde a coleta e análise de dados nas propriedades até o planejamento das atividades, certificação e rastreabilidade dos produtos. Essa tendência reflete o crescente interesse dos produtores em ampliar o uso dessas ferramentas como forma de aumentar a eficiência, reduzir perdas e garantir maior controle da produção.

Nesse contexto, Silvi *et al.* (2021) realizaram um estudo entre julho de 2018 e julho de 2020, abrangendo as principais bacias leiteiras do Brasil. Foram analisadas informações de 378 produtores distribuídos em 17 estados, permitindo a caracterização das propriedades com base em variáveis como idade do produtor, número de funcionários, tamanho do rebanho, sistema de produção, número de tecnologias adotadas e produtividade do leite. A partir desses dados, as propriedades foram agrupadas em sete *clusters* distintos, refletindo diferentes perfis produtivos e níveis de adoção tecnológica.

A Figura 5 apresenta a taxa de adoção de diferentes tecnologias entre os produtores entrevistados. Destacam-se os sistemas de medição de leite (32%), os portões inteligentes para controle da sala de ordenha (15%), os sensores para detecção de mastite (8%), os medidores de atividade das vacas (7%) e os sistemas de medição da temperatura corporal (7%).

Figura 5- Tecnologias utilizadas pelos produtores entre julho de 2018 a julho de 2020.

Adaptado de Silvi *et al.*, 2021.

Em relação aos critérios que influenciam a adoção da pecuária de precisão, os mais relevantes foram: suporte técnico disponível (45%), retorno sobre o investimento (30%), facilidade de uso (20%), custo inicial (15%) e compatibilidade com os sistemas já utilizados na fazenda (10%). Por outro lado, os principais motivos para a não adoção incluíram a prioridade de investimentos em outras áreas da propriedade (40%), a incerteza quanto ao retorno financeiro (35%) e a dificuldade de integração entre tecnologias e os sistemas existentes (25%) (Silvi *et al.*, 2021).

Um estudo conduzido por Moreira *et al.* (2024), voltado ao perfil de suinocultores brasileiros, revelou uma tendência crescente na adoção de tecnologias voltadas ao bem-estar animal e ao aumento da produtividade. Apesar de 96% dos produtores declararem utilizar práticas de gestão tecnológica, aproximadamente metade não soube indicar como o uso de indicadores específicos pode contribuir para a melhoria do desempenho produtivo. Além disso, apenas uma parcela reduzida dos entrevistados reconheceu a tecnologia como essencial para a otimização dos resultados da produção.

O perfil dos produtores avaliados indica uma predominância de profissionais de meia-idade, com formação acadêmica consistente e ampla experiência no setor. Esse grupo tem demonstrado interesse crescente em tecnologias que promovam o bem-estar animal, tanto para garantir conformidade com legislações quanto para aumentar a eficiência operacional. As propriedades analisadas apresentaram boas condições estruturais, com acesso generalizado à internet e, em muitos casos, adoção de fontes renováveis de energia — características alinhadas às exigências da pecuária de precisão (Moreira *et al.*, 2024).

A pesquisa também destacou que a combinação de infraestrutura adequada e sistemas avançados de informação é um elemento-chave para a implementação bem-sucedida da pecuária de precisão. Mais da metade dos produtores reconheceu os ganhos econômicos oriundos do uso de tecnologias, principalmente no que se refere à rentabilidade. No entanto, a resistência dos funcionários à adoção dessas ferramentas foi apontada como uma barreira significativa, mencionada por quase 90%

dos entrevistados, o que compromete a velocidade de disseminação em larga escala (Moreira *et al.*, 2024).

Os autores concluem que o perfil dos produtores brasileiros é heterogêneo, incluindo desde propriedades altamente tecnificadas até estabelecimentos de menor porte e baixa adoção tecnológica. Ainda assim, observa-se uma crescente conscientização acerca dos benefícios da pecuária leiteira de precisão (PLP), o que tem incentivado os produtores a buscar soluções inovadoras que aumentem sua competitividade frente ao avanço de produtos importados.

Ao comparar os resultados com pesquisas realizadas na cadeia leiteira, nota-se que, embora a adoção tecnológica esteja em expansão, os desafios persistem — destacando-se a integração dos sistemas existentes e a resistência dos operadores. Apesar disso, o avanço na infraestrutura e o crescente reconhecimento dos benefícios da PLP apontam para um cenário promissor, tanto em termos de produtividade quanto de promoção do bem-estar animal em diversas cadeias agropecuárias.

5 PECUÁRIA LEITEIRA DE PRECISÃO (PLP)

A produção animal global tem passado por transformações significativas, impulsionadas pela crescente demanda por alimentos de origem animal e pelas crescentes preocupações com a sustentabilidade e o bem-estar dos animais (Charlton & Rutter, 2017; Bianchi *et al.*, 2022). Estima-se que, até 2050, a produção mundial desses alimentos precisará aumentar em cerca de 70%, em resposta ao crescimento populacional e à urbanização (Berckmans, 2017). No entanto, esse desafio é acompanhado por questões éticas, ambientais e de saúde pública, como o aumento das emissões de gases de efeito estufa, o uso indiscriminado de antibióticos e o distanciamento crescente entre produtores e animais, resultado da intensificação dos sistemas de produção (Asman & Janssen, 1987; União Europeia, 2011; Fournel *et al.*, 2017).

A redução do número de propriedades leiteiras e o aumento da produtividade individual refletem a transição para sistemas mais intensivos e especializados. Em diversos países, observa-se a diminuição do número de fazendas concomitantemente ao crescimento dos rebanhos e à elevação da produção por animal (Barkema *et al.*, 2015). Embora mais eficientes, esses sistemas dificultam o monitoramento individualizado dos animais, comprometendo a oferta de cuidados personalizados (Berckmans, 2014). A crescente complexidade das demandas — como a garantia da qualidade do leite, a saúde e o bem-estar animal, o manejo ambiental e a viabilidade econômica — pressiona os produtores a adotar tecnologias que conciliem eficiência produtiva com sustentabilidade (Lovarelli *et al.*, 2019).

Entretanto, a intensificação enfrenta barreiras adicionais, como a baixa conectividade em áreas rurais, que limita o acesso a tecnologias digitais fundamentais para o monitoramento contínuo de grandes rebanhos (Moreira *et al.*, 2024). Propriedades com milhares de animais frequentemente

enfrentam dificuldades no controle de enfermidades e no gerenciamento eficiente dos dados relacionados à saúde e à produtividade (Berckmans, 2017). Nesse contexto, práticas convencionais tornam-se insuficientes, reforçando a necessidade de modernização tecnológica (Berckmans, 2014).

O crescente interesse público pelo bem-estar animal também tem impulsionado mudanças nas práticas da cadeia leiteira. Consumidores valorizam sistemas que assegurem ambientes mais naturais e manejos éticos, o que exige que os produtores equilibrem as expectativas do mercado com a viabilidade econômica (Cardoso *et al.*, 2016). Diversos estudos demonstram que práticas que priorizam o bem-estar animal podem melhorar tanto a produtividade quanto a qualidade dos produtos, abrindo espaço para a adoção de tecnologias como sensores, sistemas automatizados e algoritmos preditivos (Meen *et al.*, 2015; Bahlo *et al.*, 2019).

Nesse cenário, a Pecuária Leiteira de Precisão (PLP) emerge como uma abordagem estratégica e indispensável. Utilizando tecnologias inovadoras — como sensores inteligentes, inteligência artificial e automação —, a PLP permite o monitoramento individualizado dos animais, promovendo ganhos significativos em sustentabilidade, eficiência produtiva e bem-estar animal (Bewley, 2017; King, 2017). Seu objetivo central é otimizar o desempenho individual de cada animal, assegurando elevada produtividade, baixo custo, reduzida pegada ambiental e maior qualidade e segurança dos produtos (Rosell-Polo *et al.*, 2015). A coleta e análise de dados individualizados subsidiam decisões mais precisas sobre saúde, nutrição e manejo ao longo de todo o ciclo de vida produtivo (Qiao *et al.*, 2021).

A tecnologia de identificação individual é um pilar essencial da PLP. A rastreabilidade das características de cada animal ao longo do tempo possibilita um gerenciamento mais eficaz do rebanho, com intervenções pontuais e personalizadas (Awad, 2016). Assim, a PLP vai além da simples coleta de dados: oferece informações acionáveis que otimizam práticas como a gestão do pasto, a formulação de dietas e o monitoramento sanitário (Rutter, 2012).

Além disso, a PLP contribui para o monitoramento em tempo real da produção, da saúde animal e do impacto ambiental das propriedades, possibilitando a criação de sistemas de gestão adaptativos e inteligentes (Berckmans, 2014; Charlton & Rutter, 2017). Entre seus benefícios ambientais, destacam-se o uso mais eficiente de recursos, a detecção precoce de doenças e a mitigação das emissões de poluentes (Uwizeye *et al.*, 2016; Zucali *et al.*, 2020).

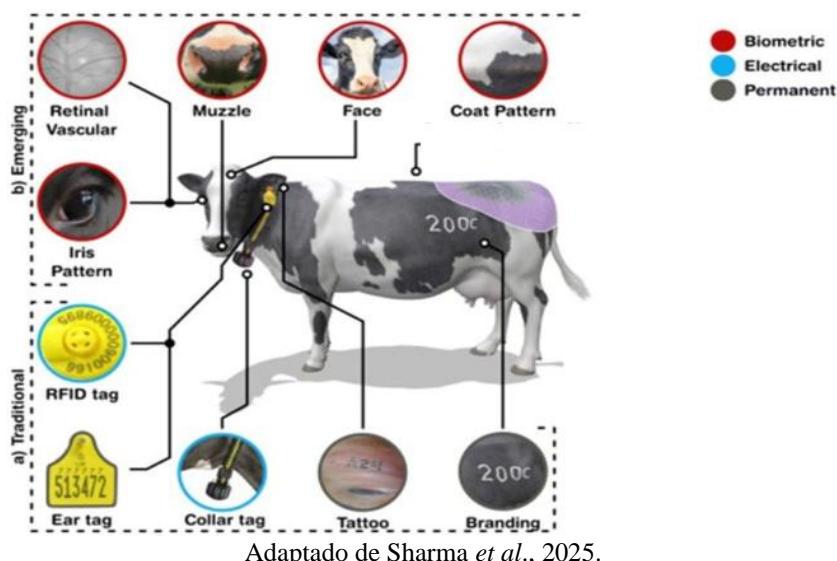
A intensificação sustentável da produção pecuária é considerada um dos maiores desafios da agricultura contemporânea (Lindblom *et al.*, 2017). Nesse contexto, a PLP representa uma solução promissora, ao aliar inovação tecnológica à necessidade de atender às crescentes demandas globais por alimentos com menor impacto ambiental e maior rastreabilidade (Tullo *et al.*, 2019).

6 IDENTIFICAÇÃO INDIVIDUAL DE ANIMAIS

A identificação individual de animais é essencial na gestão de rebanhos, garantindo a rastreabilidade, o controle de doenças e o cumprimento de exigências legais. No Brasil, as diretrizes para a rastreabilidade de bovinos e búfalos estão regulamentadas por lei (BRASIL, 2009), o que facilita a determinação da origem e da propriedade dos animais, além de contribuir para a prevenção de furtos, fraudes e para o fortalecimento da vigilância sanitária, especialmente no combate à erradicação de doenças (Smith *et al.*, 2005). O rastreamento é realizado por meio de banco de dados nacionais vinculados a identificadores exclusivos, como as marcas auriculares (Shanahan *et al.*, 2009).

Historicamente, métodos convencionais de identificação, como a marcação auricular e a ferro, foram amplamente utilizados. A marcação auricular, que consiste na fixação de etiquetas com números ou letras nas orelhas dos animais, ainda é prática comum devido à sua acessibilidade e baixo custo (Xu *et al.*, 2024). No entanto, sua durabilidade é limitada, pois fatores como fricções e mastigações podem causar a perda do dispositivo ou apagar as informações (Sherwin, 1990). A marcação a ferro, por sua vez tem sido progressivamente proibida em diversos países devido a preocupações com o bem-estar animal (Xu *et al.*, 2024). Esses métodos tradicionais estão ilustrados na Figura 6a, o qual mostra as técnicas de identificação por marcação a ferro, tatuagem e etiquetas auriculares.

Figura 1- Principais métodos de identificação animal. (a) Técnicas tradicionais, como marcação a ferro, tatuagem, etiquetas auriculares, colares e dispositivos de identificação por radiofrequência (RFID). (b) Técnicas emergentes baseadas em biometria, incluindo padrões de pelagem, características faciais, íris, retina vascular e focinho, associadas ao uso de visão computacional e redes neurais.



Adaptado de Sharma *et al.*, 2025.

Apesar de desempenharem um papel importante no passado, esses métodos apresentam limitações em relação às necessidades atuais, principalmente por dependerem de observação manual e não oferecerem automatização, o que é cada vez mais necessário em fazendas de grande porte (Ungar

et al., 2005). Ademais, os procedimentos podem causar dor e aumentar o risco de infecções, destacando a necessidade urgente de soluções mais eficazes e éticas (Fosgate *et al.*, 2006; Schnaider *et al.*, 2022).

Como alternativa, tecnologias de identificação por radiofrequência (RFID), mostradas na Figura 9a, têm ganhado destaque, permitindo a coleta automatizada de dados e aprimorando a eficiência das operações, além de reduzir o erro humano (Awad, 2016). Contudo, desafios como a perda de dispositivos, danos aos identificadores e limitações no alcance do sinal ainda representam obstáculos para a aplicação ideal dessa tecnologia (Williams *et al.*, 2019). Entretanto, os sistemas RFID têm sido amplamente adotados como uma solução emergente (Ruiz-Garcia e Lunadei, 2011).

À medida que o setor pecuário enfrenta crescentes demandas socioeconômicas e exigências de mercado, torna-se essencial a transição para métodos mais avançados. O monitoramento manual é limitado por sua baixa precisão e alto custo de mão de obra, além de não ser capaz de fornecer informações em tempo real (QIAO *et al.*, 2021). Dessa forma, a identificação individual de vacas leiteiras surge como uma solução na pecuária de precisão, permitindo rastrear produtos lácteos, monitorar comportamentos e prevenir doenças de forma mais eficiente (QIAO *et al.*, 2021; Wang *et al.*, 2023).

O avanço de tecnologias automatizadas, como a visão computacional e *deep learning*, marca um novo estágio na modernização da identificação e do monitoramento de animais, ilustrado na Figura 9b. O uso de câmeras e algoritmos avançados permite à coleta de dados complexos sobre saúde, comportamento e produtividade dos rebanhos, oferecendo suporte para decisões informadas em tempo real. Embora sua implementação exija métodos estatísticos e computacionais robustos para processar os grandes volumes de dados gerados pelas imagens, esse é um desafio técnico que está sendo superado (Oliveira *et al.*, 2021; Qiao *et al.*, 2021).

O monitoramento remoto e em tempo real, associado à visão computacional, tem se mostrado fundamental para a análise da saúde do rebanho, auxiliando no controle de surtos, na prevenção de doenças e no atendimento às exigências de agências reguladoras nacionais (Andrew *et al.*, 2021).

Paralelamente, a utilização de *deep learning* consolidou-se como uma solução inovadora para o monitoramento da saúde e do bem-estar animal, permitindo a automação de fenótipos difíceis de medir manualmente, como o peso corporal e medidas biométricas (Oliveira *et al.*, 2021). Assim, a integração dessas tecnologias com a identificação individual representa um avanço significativo na gestão do rebanho, permitindo decisões mais precisas e adaptativas (Kendrick, 1998).

A identificação individual em sistemas de produção leiteira pode ser aprimorada por meio de características biométricas únicas, como o focinho, a retina, características faciais e padrões de pelagem (figura 9.b). Essas características têm se mostrado eficazes em abordagens não invasivas para a identificação, utilizando tecnologias como visão computacional e análise de dados (Arslan *et al.*,

2014; Andrew *et al.*, 2016). A aplicação dessas características pode ser dividida em três categorias principais: focinho, retina/íris e características faciais/padrão de pelagem (Andrew *et al.*, 2017).

Pesquisas indicam que, ao combinar essas características biométricas com tecnologias de visão computacional, é possível identificar vacas com alta precisão, minimizando a interrupção de suas atividades diárias. O focinho, o rosto e o tronco são frequentemente utilizados como regiões de interesse (ROI) para essa identificação, permitindo o reconhecimento com base em traços específicos de cada animal (Bhole *et al.*, 2022; Kaur *et al.*, 2022; Xu *et al.*, 2022). Além disso, o padrão de pelagem, devido às suas características próprias de cada raça, tem sido aproveitado para um monitoramento contínuo e não intrusivo do rebanho (Kühl e Burghardt, 2013).

A biometria do gado, iniciada por Petersen (1922) com o focinho, foi expandida para incluir outras características, como a retina, o rosto e varreduras corporais (Andrew *et al.*, 2021). Essas tecnologias exigem imagens especializadas, que têm o potencial de fornecer informações essenciais sobre o comportamento e a saúde dos animais, sem a necessidade de contato físico, minimizando os riscos de infecção ou interferência nas respostas do rebanho (Berckmans, 2014).

Tecnologias de imagem em tempo real, associadas à análise de dados avançada, possibilitam o monitoramento de comportamentos e sinais de estresse, otimizando o manejo e prevenindo problemas de saúde (Oczak *et al.*, 2013). Esses avanços facilitam a coleta contínua de dados que, quando analisados por métodos estatísticos, contribuem para a detecção precoce de condições anormais, garantindo a saúde e o bem-estar dos animais (Fournel *et al.*, 2017).

O focinho tem sido utilizado como característica biométrica devido aos padrões únicos presentes em cada animal, com estudos indicando que os padrões do focinho são semelhantes às impressões digitais humanas (Baranov *et al.*, 1993). Apesar disso, o uso do focinho enfrenta desafios práticos, como o acúmulo de restos durante a alimentação, o que pode prejudicar a precisão dos algoritmos de reconhecimento. Além disso, a captura das imagens em condições reais de manejo exige a contensão do animal, o que não é viável em sistemas de Pecuária Leiteira de Precisão (Xu *et al.*, 2024).

Barry *et al.* (2007) realizaram um estudo com 29 vacas, utilizando imagens em tons de cinza dos padrões do focinho. O reconhecimento foi realizado com base na Análise de Componentes Principais (PCA) e a distância euclidiana entre os vetores de características, alcançando uma precisão de 98,85%. O uso de imagens de focinho capturadas por câmeras digitais tem sido sugerido como uma forma prática de coletar dados (Qiao *et al.*, 2021). Contudo, essas técnicas dependem da obtenção de imagens restritas do focinho, o que limita sua aplicabilidade em condições normais de manejo (Andrew *et al.*, 2021).

Padrões vasculares da retina e íris também têm sido explorados para a identificação. Esses padrões são estáveis ao longo do tempo, mas a captura de imagens da retina e da íris de animais em movimento ainda é um desafio (Allen *et al.*, 2008). O estudo de Sun *et al.* (2013) demonstrou que a técnica de contorno ativo e o algoritmo SIFT (*Scale-Invariant Feature Transform*) para análise da íris alcançaram uma taxa de precisão de 98,15%, mostrando a eficácia desses métodos.

A identificação com base em padrões de pelagem e características corporais oferece vantagens práticas devido à facilidade de captura das imagens (Xu *et al.*, 2024). Andrew *et al.* (2016) utilizaram descritores locais de pelagem combinados com SVM (*Support Vectors Machine*), alcançando uma precisão de 97% na identificação de vacas leiteiras. Esses métodos têm se mostrado eficazes em sistemas de identificação baseados em características visuais.

A utilização de representações tridimensionais, como observado no estudo de Ferreira *et al.* (2022), também tem sido promissora, permitindo a análise de dados 2D e 3D através de redes neurais, oferecendo uma abordagem robusta para a identificação ao longo do ciclo de vida do animal a partir de características biométricas da região dorsal.

A identificação individual de vacas leiteiras, por meio de tecnologias como visão computacional e biometria, oferece avanços significativos no manejo do rebanho, otimizando a rastreabilidade, a saúde e o bem-estar animal. Todavia, desafios como variações na iluminação e nos ângulos de captura podem afetar a precisão dos modelos. Assim, a implementação de processos rigorosos de pré-processamento e seleção de características é essencial para assegurar a confiabilidade dos resultados (Qiao *et al.*, 2021).

7 APRENDIZADO PROFUNDO NA IDENTIFICAÇÃO ANIMAL

As abordagens de aprendizado profundo têm demonstrado grande potencial na identificação de animais, especialmente por sua capacidade de extrair características de imagens sem necessidade de pré-especificação (Andrew *et al.*, 2017; Qiao *et al.*, 2021). Essas técnicas, que ampliaram suas aplicações em visão computacional, permitem previsões não invasivas e em tempo real sobre a saúde, bem-estar e produtividade do gado (Oliveira *et al.*, 2021).

Estudos indicam que o aprendizado profundo extrai características das imagens de forma mais eficiente e robusta do que os métodos tradicionais de aprendizado de máquina (Chen *et al.*, 2023). Nesse contexto, torna-se possível realizar o monitoramento contínuo dos animais e tomar decisões estratégicas fundamentadas (Halachmi e Guarino, 2016; Mahmud *et al.*, 2021). Ademais, essas tecnologias facilitam a detecção precoce de doenças, a estimativa do escore corporal e a otimização da alimentação, contribuindo diretamente para a sustentabilidade e a eficiência da produção pecuária (Banhazi *et al.*, 2012).

O aprendizado profundo também tem sido empregado em desafios mais complexos, como a detecção de claudicação e o monitoramento do bem-estar animal, utilizando imagens captadas em solo ou por drones (Gjergji *et al.*, 2020; Kang *et al.*, 2020; Xu *et al.*, 2020). A identificação baseada em biometria visual, como padrões de pelagem e contornos corporais, explora a singularidade dessas características, permitindo a identificação precisa e eficiente de cada animal (Zhao e He, 2015; Andrew *et al.*, 2016). Em sistemas modernos de criação, essas tecnologias são fundamentais para superar desafios como a escassez de mão de obra e a necessidade de monitoramento individualizado (Meen *et al.*, 2015; Nikander *et al.*, 2015). Adicionalmente, o monitoramento contínuo viabiliza a identificação de comportamentos atípicos e a detecção precoce de anomalias, tornando-se essenciais para aprimorar a gestão pecuária (Bishop *et al.*, 2019).

A implementação de modelos de aprendizado profundo na pecuária ocorre em duas etapas principais: primeiro, o algoritmo é treinado com um conjunto de dados representativo e, em seguida, validado com dados distintos, o que permite avaliar sua precisão e capacidade preditiva (Mahmud *et al.*, 2021). O uso de vídeos, que capturam aspectos espaciais e temporais do comportamento dos animais, como a marcha, tem se mostrado uma ferramenta promissora para fornecer informações ricas e detalhadas (Frost *et al.*, 1997), embora sua análise requeira técnicas avançadas de processamento de dados (Qiao *et al.*, 2019).

Entretanto, um dos principais desafios na implementação de modelos de aprendizado profundo é a necessidade de grandes volumes de dados para garantir a precisão dos modelos (Van Hertem *et al.*, 2017). A coleta desses dados deve ser eficiente e integrada, visto que, em muitas implementações, os dados provenientes de diferentes fontes não se comunicam de forma eficaz, comprometendo a confiabilidade das informações. Isso pode dificultar a tomada de decisões, caso os dados não sejam processados adequadamente. Além disso, a análise dos grandes volumes de dados precisa ser clara e acessível aos agricultores, garantindo decisões rápidas e precisas.

A pecuária leiteira de precisão, por muitos anos, focou-se em aspectos específicos. No entanto, para lidar com a complexidade das interações entre diversos fatores, é necessário o uso de ferramentas mais avançadas e com maior capacidade de análise de dados (Sonka e Cheng, 2015). A integração de diferentes fontes de dados e a troca de informações entre sistemas de diferentes fabricantes são desafios ainda que representam um desafio na pecuária leiteira. A falta de uma gestão adequada dessas informações limita sua aplicabilidade, impactando diretamente a tomada de decisões estratégicas no setor (Nikander *et al.*, 2015).

Ademais, a qualidade das imagens é um fator determinante para o desempenho dos modelos de aprendizado profundo. Imagens de baixa qualidade podem prejudicar a precisão dos resultados, e melhorar sua qualidade frequentemente implica em tempos maiores para o processamento dos dados.

A escassez de dados ou a presença de conjuntos de dados desequilibrados também pode reduzir a precisão dos modelos, evidenciando a necessidade de grandes volumes de dados de alta qualidade para treinamento e teste (Mahmud *et al.*, 2021).

A criação de padrões claros para a avaliação e comparação entre os métodos existentes também é outro desafio. Para isso, a criação de conjuntos de dados de referência, como imagens biométricas de gado, é essencial para a avaliação de algoritmos de extração de características e classificação (Qiao *et al.*, 2021). Esses padrões são fundamentais para garantir a comparabilidade entre diferentes algoritmos e melhorar a precisão das tecnologias utilizadas.

Durante a implementação de sistemas de monitoramento, Van Hertem *et al.* (2017) observaram que falhas de comunicação e erros no registro manual de dados comprometeram a coleta e a precisão dos resultados. A confiança dos produtores na tecnologia depende, em grande parte, da precisão dos sensores e dos sistemas de coleta de dados, o que destaca a necessidade de investimentos em qualidade e manutenção desses sistemas.

A pesquisa de Nikander *et al.* (2015) exemplifica o potencial da integração de dados na gestão de rebanhos. O sistema *Cowlab ACIS*, desenvolvido para centralizar informações provenientes de diversos subsistemas, demonstrou elevada eficácia na organização e análise em tempo real desses dados. A integração com o banco de dados nacional de registro de animais e laboratórios de análise de leite facilitou a tomada de decisões rápidas e precisas, reduzindo o tempo necessário para manipulação dos dados e possibilitando a geração de relatórios automáticos e alertas para falhas técnicas.

8 ALGORITMOS DE APRENDIZADO PROFUNDO

O avanço tecnológico tem impulsionado melhorias significativas na agricultura e na pecuária, especialmente no setor leiteiro. A utilização das Tecnologias da Informação e Comunicação (TIC) permitiu o processamento eficiente de grandes volumes de dados, contribuindo para uma gestão otimizada (Vranken e Berckmans, 2017). A adoção dessas inovações tem aumentado a eficiência produtiva, possibilitando a previsão e análise do comportamento dos animais, o que resulta em uma gestão mais eficaz (Espinosa *et al.*, 2016).

Dentro desse contexto, a detecção dos animais pode ser dividida em três etapas principais: segmentação, extração de características e identificação. A segmentação é responsável por separar os animais do fundo, enquanto a extração de características envolve a identificação de movimentos, orientações e outras informações pertinentes. A identificação, por sua vez, foca nas regiões de interesse (ROI), que são utilizadas para reconhecer traços específicos individuais (Wurtz *et al.*, 2019; Kaur *et al.*, 2022).

Para identificar o animal individualmente, são empregados algoritmos de aprendizado supervisionado. Após a segmentação e extração de características, esses algoritmos são utilizados para modelar e classificar os dados (Williams *et al.*, 2019). A validação do modelo deve ser realizada com dados que não foram utilizados durante o treinamento, permitindo testar o algoritmo em novas condições ambientais, como variações de luz, fundo e tempo (Psota *et al.*, 2019).

Cabe destacar que a identificação pode variar de acordo com as características da espécie em questão. Por exemplo, vacas leiteiras, que possuem movimentos mais lentos e padrões visuais distintos, podem ser rastreadas individualmente de maneira mais eficiente do que animais de movimento rápido, como galinhas. Isso resulta em uma variedade de abordagens metodológicas relatadas na literatura (Wurtz *et al.*, 2019).

Além disso, a escolha das técnicas de segmentação e extração de características depende de diversos fatores, como os objetivos da pesquisa, as condições experimentais e as espécies envolvidas. Essa diversidade de métodos reflete, em parte, a falta de padronização nos diferentes campos de pesquisa, evidenciando a necessidade de uma maior colaboração interdisciplinar (Wurtz *et al.*, 2019).

O aprendizado supervisionado, amplamente utilizado na pecuária de precisão, envolve o treinamento de algoritmos com dados rotulados para realizar tarefas de classificação. Esse método é popular por permitir previsões baseadas em conhecimento prévio, facilitando sua implementação. No entanto, o aprendizado supervisionado pode apresentar desafios, como o sobreajuste e limitações nas decisões, especialmente quando o conjunto de dados de treinamento não é suficientemente representativo (Mahmud *et al.*, 2021). Técnicas como validação cruzada, normalização de lotes e aumento de dados são frequentemente utilizadas para mitigar esses problemas e aprimorar a capacidade de generalização dos algoritmos (Yadav e Shukla, 2016).

A técnica de aprendizado por transferência tem se mostrado uma estratégia eficaz, principalmente em tarefas de reconhecimento de imagens e comportamentos. Redes neurais profundas, previamente treinadas em grandes bases de dados, podem ser adaptadas a novos problemas com um número reduzido de dados rotulados (Pan e Yang, 2009). Essa abordagem destaca-se na pecuária de precisão, onde a escassez de dados específicos torna os modelos pré-treinados uma solução eficiente para melhorar o desempenho e agilizar a implementação (Mahmud *et al.*, 2021).

8.1 CLASSIFICADORES

Diversos algoritmos têm sido aplicados na pecuária, destacando-se a Rede Neural Convolucional (CNN), amplamente utilizada por sua precisão e simplicidade. Embora não seja a mais eficiente em todos os casos, a CNN se destaca pela boa acurácia e facilidade de implementação (Mahmud *et al.*, 2021). No estudo de Andrew *et al.* (2017) foi aplicada a Rede Neural Convolucional

Regional (R-CNN) para localizar e identificar vacas holandesas em imagens capturadas por drones. A R-CNN combina as tarefas de localização e classificação de objetos, atingindo cerca de 86% de precisão, utilizando um modelo previamente treinado com o banco de dados *ImageNet*.

Shen *et al.* (2020) ajustaram uma CNN para identificar vacas leiteiras em imagens de visão lateral. Devido às dificuldades em identificar padrões com métodos tradicionais em vacas com características texturais menos evidentes, os autores utilizaram o modelo *AlexNet*, alcançando aproximadamente 97% de precisão na identificação das vacas.

A Máquina de Vetor de Suporte (SVM) é outro algoritmo eficaz em tarefas de classificação, pois é capaz de identificar um hiperplano que separa as classes de dados de maneira eficiente (Gholami e Fakhari, 2017). No estudo de Xiao *et al.* (2022), a SVM foi utilizada para identificar vacas leiteiras, considerando os padrões presentes nas costas dos bovinos. O modelo alcançou uma precisão de cerca de 99%, embora tenha enfrentado dificuldades em identificar vacas com padrões brancos pequenos ou ausentes, o que comprometeu a extração de características e causou erros na classificação.

O algoritmo K-vizinho mais próximo (K-NN), uma técnica de classificação não paramétrica, é amplamente utilizado devido à sua simplicidade e eficácia no reconhecimento de padrões (Belfiore e Rudas, 2014). O K-NN classifica um ponto de dados com base na maioria dos votos de seus *k* vizinhos mais próximos, utilizando, comumente, a distância euclidiana como medida de proximidade entre os pontos (Gazalba *et al.*, 2017). A escolha do valor de *k* é fundamental para o desempenho do modelo, já que valores muito pequenos podem torná-lo sensível a outliers, enquanto valores muito grandes podem diluir as diferenças entre as classes. Além disso, recomenda-se o uso de um valor ímpar de *k* para evitar empates nas classificações (Gou *et al.*, 2019).

No estudo de Naimi *et al.* (2022), seis classificadores K-NN foram testados, sendo que o K-NN ponderado apresentou o melhor desempenho. A pesquisa demonstrou que o K-NN é competitivo em relação a algoritmos mais complexos, como o SVM. Cutler *et al.* (2012) sugerem que o K-NN pode ser ajustado para otimizar o valor de *k*, aumentando sua flexibilidade e eficácia em sistemas de classificação baseados na similaridade de características dos dados.

Andrew *et al.* (2021) demonstraram o uso do K-NN no reconhecimento de bovinos *Holstein-Friesian*, empregando o algoritmo após uma rede de incorporação. O sistema identificou bovinos conhecidos e desconhecidos sem a necessidade de re-treinamento. Esse estudo ilustra a flexibilidade e eficácia do K-NN em situações práticas, onde as características dos animais podem variar.

O algoritmo *Random Forest* é outra técnica de aprendizado supervisionado, composta por um conjunto de árvores de decisão que realizam classificações simultaneamente (Zawbaa *et al.*, 2014). Cada árvore usa amostras aleatórias dos dados e o resultado final é obtido por meio de uma votação entre as árvores. Sua principal vantagem é a flexibilidade e a facilidade de uso, sendo também eficaz

na avaliação da importância dos atributos para a classificação (Cutler *et al.*, 2012). No estudo de Sajwan e Ranjan (2019), o algoritmo obteve uma acurácia de aproximadamente 98% na classificação de imagens de flores, sendo capaz de classificar corretamente sete das dez classes do conjunto de dados.

As Redes Neurais (NN) são amplamente utilizadas em tarefas de inteligência artificial e aprendizado de máquina, inspiradas no funcionamento dos neurônios do cérebro humano. Essas redes ajustam os pesos de suas conexões para minimizar o erro e alcançar decisões precisas (Vaishnav e Rao, 2018). Um diferencial das NN é a capacidade de realizar, de maneira integrada, a extração de características e a classificação dos dados, o que as torna uma ferramenta altamente eficiente (Kao e Kuo, 1992). Contudo, sua eficácia depende do ajuste adequado de seus parâmetros, o que pode influenciar significativamente o desempenho em diferentes contextos (Simonyan, 2014).

No estudo de Naimi *et al.* (2022), citado anteriormente, as Redes Neurais foram testadas como um dos seis classificadores aplicados a um conjunto de dados. Utilizando o gradiente conjugado para 1.000 épocas de treinamento, as NN apresentaram resultados inferiores aos obtidos por métodos como K-NN e SVM em algumas tarefas específicas. Esses resultados ressaltam tanto as limitações quanto as possibilidades das Redes Neurais, evidenciando a importância de ajustes precisos em sua configuração para maximizar seu desempenho.

8.2 EXTRATORES DE CARACTERÍSTICAS

O modelo *InceptionV3*, desenvolvido por Szegedy *et al.* (2016), é uma rede neural convolucional (CNN) otimizada para reconhecimento de imagens e atua como extrator de características. Sua arquitetura combina convoluções, camadas de agrupamento e conexões residuais, além de contar com otimizações, como a normalização de lote e a redução de camadas, o que resulta em maior eficiência computacional. Essas melhorias permitem acelerar o treinamento, reduzir a complexidade do modelo e aumentar sua eficácia em cenários de processamento de grandes volumes de dados, como no contexto de *Big Data* (Llamas *et al.*, 2017).

O modelo também apresenta melhorias como a suavização de rótulos que melhora a generalização do modelo, e sua adequação para dispositivos com recursos limitados (Mahmud *et al.*, 2021). No estudo de Andrew *et al.* (2020), o modelo foi integrado a uma rede LSTM (*Long Short-Term Memory*) para a identificação individual de vacas holandesas utilizando drones, alcançando uma precisão de 93,6%. Outro exemplo é o experimento de Qiao *et al.* (2019), que empregou o *InceptionV3* para extrair características visuais de vídeos de gado. Nesse caso, a precisão de identificação aumentou com o número de quadros analisados, atingindo 91% ao utilizar 20 quadros por vez.

8.3 MODELOS DE DETECÇÃO DE OBJETOS

O *YOLO* (*You Only Look Once*), desenvolvido por Redmon *et al.* (2016), é uma arquitetura amplamente reconhecida por sua eficiência e rapidez na detecção de objetos. Diferentemente de métodos como a R-CNN, que exigem múltiplas avaliações para localizar e classificar objetos, o *YOLO* processa a imagem inteira em uma única passagem pela rede, localizando e classificando os objetos de forma simultânea. Essa abordagem reduz significativamente o tempo de processamento e aumenta a eficiência do modelo.

Tassinari *et al.* (2021) aplicaram o *YOLO* para identificar vacas individuais em um sistema *free-stall*, baseando-se nos padrões de pelagem preta e branca de cada animal. O modelo foi treinado para detectar oito classes, representando diferentes vacas e seus quadris. A validação demonstrou resultados promissores, com algumas classes apresentando maior precisão, destacando o potencial do *YOLO* para a gestão e monitoramento de rebanhos.

No estudo de Hu *et al.* (2020), o *YOLO* foi utilizado como parte de um sistema de identificação de vacas em que as imagens eram segmentadas em partes específicas, como cabeça, tronco e pernas. As características de cada segmento foram extraídas e combinadas, resultando em uma precisão de 98,4%, superando métodos anteriores. Além disso, o modelo mostrou-se versátil, com aplicações potenciais na análise comportamental e no monitoramento da saúde animal.

Zhao e Lian (2022) propuseram uma abordagem baseada no *YOLOv4* para identificar gado a partir de imagens capturadas de múltiplos ângulos. O modelo explorou as características físicas das raças para realizar a identificação, mesmo em condições desafiadoras, como oclusões parciais e posturas variadas. O estudo, conduzido em ambientes reais de fazendas, destacou a capacidade do *YOLOv4* em monitorar rebanhos, embora dificuldades tenham sido observadas em casos de alta similaridade entre indivíduos.

Por sua vez, Xu *et al.* (2024) avançaram no uso do *YOLOv5* para a identificação de vacas, com foco na redução de custos de rotulagem e na adaptação à rotatividade dos rebanhos. O modelo aprimorado permitiu uma detecção precisa e eficiente dos animais, enquanto a integração da técnica de meta-aprendizagem *Model-Agnostic Meta-Learning* (MAML) possibilitou atualizações rápidas com poucas amostras. Essa abordagem destacou-se pela flexibilidade, permitindo a inclusão automática de novos animais e comprovando a eficácia do sistema em cenários dinâmicos.

9 CONCLUSÕES

A revisão da literatura confirma que a identificação individual de vacas leiteiras é essencial para a modernização da produção, especialmente no contexto da pecuária de precisão. Tecnologias como aprendizado de máquina, visão computacional e uso de drones têm demonstrado alta precisão e

potencial de aplicação em larga escala. Modelos adaptativos permitem incluir novos animais com menos dados, ampliando a eficiência e a rastreabilidade dos rebanhos. No cenário brasileiro, a adoção de soluções acessíveis e integradas à realidade dos pequenos e médios produtores é fundamental. Pesquisas futuras devem focar na superação de barreiras práticas, promovendo a aplicação dessas tecnologias de forma eficiente, econômica e sustentável.

REFERÊNCIAS

- ALLEN, A. *et al.* Evaluation of retinal imaging technology for the biometric identification of bovine animals in Northern Ireland. **Livestock Science**, v. 116, n. 1-3, p. 42-52, 2008.
- ANDREW, W. *et al.* Automatic individual holstein friesian cattle identification via selective local coat pattern matching in RGB-D imagery. In: **2016 IEEE International Conference on Image Processing (ICIP)**. IEEE, 2016. p. 484-488.
- ANDREW, W.; GREATWOOD, C.; BURGHARDT, T. Visual localization and individual identification of holstein friesian cattle via deep learning. In: **Proceedings of the IEEE International Conference on Computer Vision Workshops**. 2017. p. 2850-2859.
- ANDREW, W.; GREATWOOD, C.; BURGHARDT, T. Fusing Animal Biometrics with Autonomous Robotics: Drone-based Search and Individual ID of Friesian Cattle. In: **2020 IEEE Winter Applications of Computer Vision Workshops (WACVW)**. IEEE, 2020. p. 38-43.
- ANDREW, W. *et al.* Visual identification of individual Holstein-Friesian cattle via deep metric learning. **Computers and Electronics in Agriculture**, v. 185, p. 106133, 2021.
- ARSLAN, A.; AKAR, M.; ALAGÖZ, F. 3D Cow identification in cattle farms. In: **2014 22nd Signal Processing and Communications Applications Conference (SIU)**. IEEE, 2014. p. 1347-1350.
- ASMAN, W.; JANSSEN, A. A long-range transport model for ammonia and ammonium for Europe. **Atmospheric Environment (1967)**, v. 21, n. 10, p. 2099-2119, 1987.
- AUGUSTO, B. S. Importância da raça holandesa na pecuária leiteira: revisão bibliográfica. 2023.
- AWAD, A. I. From classical methods to animal biometrics: A review on cattle identification and tracking. **Computers and Electronics in Agriculture**, v. 123, p. 423-435, 2016.
- BAHLO, C. *et al.* The role of interoperable data standards in precision livestock farming in extensive livestock systems: A review. **Computers and Electronics in Agriculture**, v. 156, p. 459-466, 2019.
- BANHAZI, T. *et al.* Precision livestock farming: an international review of scientific and commercial aspects. **International Journal of Agricultural and Biological Engineering**, v. 5, n. 3, p. 1-9, 2012.
- BARANOV, A. S. *et al.* Breed differences and intra-breed genetic variability of dermatoglyphic pattern of cattle. **Journal of Animal Breeding and Genetics**, v. 110, n. 1-6, p. 385-392, 1993.
- BARKEMA, H. *et al.* Invited review: Changes in the dairy industry affecting dairy cattle health and welfare. **Journal of Dairy Science**, v. 98, n. 11, p. 7426-7445, 2015.
- BARRY, B. *et al.* Using muzzle pattern recognition as a biometric approach for cattle identification. **Transactions of the ASABE**, v. 50, n. 3, p. 1073-1080, 2007.
- BELFIORE, N.; RUDAS, I. Applications of computational intelligence to mechanical engineering. In: **2014 IEEE 15th international symposium on computational intelligence and informatics (CINTI)**. IEEE, 2014. p. 351-368.
- BERCKMANS, D. Precision livestock farming technologies for welfare management in intensive livestock systems. **OIE Revue Scientifique et Technique**, v. 33, n. 1, p. 189-196, 2014.
- BERCKMANS, D. General introduction to precision livestock farming. **Animal Frontiers**, v. 7, n. 1, p. 6-11, 2017.
- BEWLEY, J. Exploring the potential of precision dairy tools. 2017.

BHOLE, A. *et al.* CORF3D contour maps with application to Holstein cattle recognition from RGB and thermal images. **Expert Systems with Applications**, v. 192, p. 116354, 2022.

BIANCHI, M. C. *et al.* Diffusion of precision livestock farming technologies in dairy cattle farms. **Animal**, v. 16, n. 11, p. 100650, 2022.

BISHOP, J. *et al.* Livestock vocalisation classification in farm soundscapes. **Computers and Electronics in Agriculture**, v. 162, p. 531-542, 2019.

BOLFE, E. *et al.* Tecnologias digitais na pecuária: aplicações, desafios e expectativas. **Campo Grande: Boletim Cicarne**, 2021.

BRASIL. Instituto Brasileiro de Geografia e Estatística (IBGE). **Produção de leite**. Disponível em: <https://www.ibge.gov.br/explica/producao-agropecuaria/leite/br>. Acesso em: 09 jul. 2024.

BRASIL. Lei nº 12.097, de 24 de novembro de 2009. Dispõe sobre a rastreabilidade na cadeia produtiva de bovinos e búfalos. Brasília, DF: **Diário Oficial da União**, 2009.

BRASIL, MAPA. Ministério da Agricultura e Pecuária. **MAPA DO LEITE**. Disponível em: <https://www.gov.br/agricultura/pt-br/assuntos/producao-animal/mapa-do-leite>. Acesso em: 09 jul. 2024.

CARDOSO, C. *et al.* Imagining the ideal dairy farm. **Journal of Dairy Science**, v. 99, n. 2, p. 1663-1671, 2016.

CHARLTON, G.; RUTTER, S. The behaviour of housed dairy cattle with and without pasture access: A review. **Applied Animal Behaviour Science**, v. 192, p. 2-9, 2017.

CHEN, X. *et al.* Chinese mitten crab detection and gender classification method based on GMNet-YOLOv4. **Computers and Electronics in Agriculture**, v. 214, p. 108318, 2023.

CUTLER, A.; CUTLER, D.; STEVENS, J. *Random Forests. Ensemble Machine Learning: Methods and Applications*, p. 157-175, 2012.

EMBRAPA. **Anuário Leite 2024**: avaliação genética multirracial, 2024. Disponível em: <https://www.embrapa.br/busca-de-publicacoes/-/publicacao/1164754/anuario-leite-2024-avaliacao-genetica-multirracial>. Acesso em: 09/07/2024.

EMBRAPA, GADO DE LEITE. Centro de Inteligência do Leite–CILeite. **Nota de Conjuntura: Mercado de Leite e Derivados**, setembro de 2024.

ESPINOSA, H.; BASTIDAS D.; NARANJO A. Application of Geographic Information Systems (GIS) for the implementation of precision farming. **Livestock Research for Rural Development**, 2016.

ESTADOS UNIDOS. Department of Agriculture. **Dairy and Products Annual - United States Department of Agriculture**. Disponível em: https://apps.fas.usda.gov/newgainapi/api/Report/DownloadReportByFileName?fileName=Dairy%20and%20Products%20Annual_Brasilia_Brazil_BR2023-0026.pdf. Acesso em: 09 jul. 2024.

FERREIRA, R. *et al.* Using dorsal surface for individual identification of dairy calves through 3D deep learning algorithms. **Computers and Electronics in Agriculture**, v. 201, p. 107272, 2022.

FOSGATE, G. T.; ADESIYUN, A. A.; HIRD, D. W. Ear-tag retention and identification methods for extensively managed water buffalo (*Bubalus bubalis*) in Trinidad. **Preventive Veterinary Medicine**, v. 73, n. 4, p. 287-296, 2006.

FOURNEL, S.; ROUSSEAU, A.; LABERGE, B. Rethinking environment control strategy of confined animal housing systems through precision livestock farming. **Biosystems Engineering**, v. 155, p. 96-123, 2017.

FROST, A. R. *et al.* A review of livestock monitoring and the need for integrated systems. **Computers and electronics in agriculture**, v. 17, n. 2, p. 139-159, 1997.

GAZALBA, I. *et al.* Comparative analysis of k-nearest neighbor and modified k-nearest neighbor algorithm for data classification. In: **2017 2nd International Conferences on Information Technology, Information Systems and Electrical Engineering (ICITISEE)**. IEEE, 2017. p. 294-298.

GHOLAMI, R.; FAKHARI, N. *Support Vector Machine*: principles, parameters, and applications. In: **Handbook of Neural Computation**. Academic Press, 2017. p. 515-535.

GIMENEZ, C. M.; SILVA, A. C. S.; ARCE, A. I. C.; MOREIRA, S. H. S.; TECH, A. R. B.; COSTA, E.J. X. Reconhecimento Biométrico de padrões do espelho nasal bovino utilizando K-nn como classificador. In: **Zootec, Maceió. Anais Zootec**, 2011. v. CD.

GJERGJI, M. *et al.* Deep learning techniques for beef cattle body weight prediction. In: **2020 International Joint Conference on Neural Networks (IJCNN)**. IEEE, 2020. p. 1-8.

GODEC, P. *et al.* Democratized image analytics by visual programming through integration of deep models and small-scale machine learning. **Nature Communications**, v. 10, n. 1, p. 4551, 2019.

GOU, J. *et al.* A generalized mean distance-based k-nearest neighbor classifier. **Expert Systems with Applications**, v. 115, p. 356-372, 2019.

HALACHMI, I.; GUARINO, M. Precision livestock farming: a 'per animal' approach using advanced monitoring technologies. **Animal**, v. 10, n. 9, p. 1482-1483, 2016.

HU, H. *et al.* Cow identification based on fusion of deep parts features. **Biosystems Engineering**, v. 192, p. 245-256, 2020.

IANDOLA, F. *SqueezeNet*: AlexNet-level accuracy with 50x fewer parameters and < 0.5 MB model size. **arXiv preprint arXiv:1602.07360**, 2016.

KANG, Xi; ZHANG, X. D.; LIU, Gang. Accurate detection of lameness in dairy cattle with computer vision: A new and individualized detection strategy based on the analysis of the supporting phase. **Journal of Dairy Science**, v. 103, n. 11, p. 10628-10638, 2020.

KAO, C.; KUO, Y. A *Neural Network* model based on fuzzy classification concept. In: **[Proceedings 1992] IJCNN International Joint Conference on Neural Networks**. IEEE, 1992. p. 727-732.

KAUR, A.; KUMAR, M.; JINDAL, M. Cattle identification with muzzle pattern using computer vision technology: a critical review and prospective. **Soft Computing**, v. 26, n. 10, p. 4771-4795, 2022.

KENDRICK, K. M. Intelligent perception. **Applied Animal Behaviour Science**, v. 57, n. 3-4, p. 213-231, 1998.

KING, A. Technology: The future of agriculture. **Nature**, v. 544, n. 7651, p. S21-S23, 2017.

KUNZE, L., HAWES, N., DUCKETT, T., HANHEIDE, M., & KRAJNÍK, T. (2018). Artificial intelligence for long-term robot autonomy: A survey. **IEEE Robotics and Automation Letters**, 3(4), 4023-4030.

KÜHL, H.; BURGHARDT, T. Animal biometrics: quantifying and detecting phenotypic appearance. **Trends in Ecology & Evolution**, v. 28, n. 7, p. 432-441, 2013.

LINDBLOM, J. *et al.* Promoting sustainable intensification in precision agriculture: review of decision support systems development and strategies. **Precision Agriculture**, v. 18, p. 309-331, 2017.

LLAMAS, Jose *et al.* Classification of architectural heritage images using deep learning techniques. **Applied Sciences**, v. 7, n. 10, p. 992, 2017.

LOVARELLI, D. *et al.* Improvements to dairy farms for environmental sustainability in Grana Padano and Parmigiano Reggiano production systems. **Italian Journal of Animal Science**, 2019.

MAHMUD, M. *et al.* A systematic literature review on deep learning applications for precision cattle farming. **Computers and Electronics in Agriculture**, v. 187, p. 106313, 2021.

MEEN, G. H. *et al.* Sound analysis in dairy cattle vocalisation as a potential welfare monitor. **Computers and Electronics in Agriculture**, v. 118, p. 111-115, 2015.

MOREIRA, M.R *et al.* The Perception of Brazilian Livestock Regarding the Use of Precision Livestock Farming for Animal Welfare. **Agriculture**, v. 14, n. 8, p. 1315, 2024.

NAIMI, A. *et al.* Fault detection and isolation of a pressurized water reactor based on *Neural Network* and k-nearest neighbor. **IEEE Access**, v. 10, p. 17113-17121, 2022.

NEETHIRAJAN, S.; KEMP, B. Digital Livestock Farming. **Sensing and Bio-Sensing Research**, p. 100408, 2021.

NIKANDER, J. *et al.* Development of a general Cowshed information management system from proprietary subsystems. In: **Proceedings of the 7th European Conference on Precision Livestock Farming**. Milano, Italy. 2015.

NOLÉTO, R.M.A *et al.* Inovações no Reconhecimento e Detecção de Animais: Uma Análise da Literatura com Ênfase em Redes Neurais e Aprendizado de Máquina. **Anais do XVI Encontro Unificado de Computação do Piauí**, p. 33-40, 2023.

OCZAK, M. *et al.* Analysis of aggressive behaviours of pigs by automatic video recordings. **Computers and electronics in agriculture**, v. 99, p. 209-217, 2013.

OLIVEIRA, D. *et al.* A review of deep learning algorithms for computer vision systems in livestock. **Livestock Science**, v. 253, p. 104700, 2021.

PAN, S.; YANG, Q. A survey on transfer learning. **IEEE Transactions on knowledge and data engineering**, v. 22, n. 10, p. 1345-1359, 2009.

PEREIRA, L. *et al.* Pecuária leiteira de precisão: conceitos e tecnologias disponíveis. **Cadernos Técnicos de Veterinária e Zootecnia**, nº 79, 2015.

PETERSEN, W. The identification of the bovine by means of nose-prints. **Journal of Dairy Science**, v. 5, n. 3, p. 249-258, 1922.

PSOTA, E. *et al.* Multi-pig part detection and association with a fully-convolutional network. **Sensors**, v. 19, n. 4, p. 852, 2019.

QIAO, Y. *et al.* Individual cattle identification using a deep learning based framework. **IFAC-PapersOnLine**, v. 52, n. 30, p. 318-323, 2019.

QIAO, Y. *et al.* Intelligent perception for cattle monitoring: A review for cattle identification, body condition score evaluation, and weight estimation. **Computers and Electronics in Agriculture**, v. 185, p. 106143, 2021.

REDMON, J. *et al.* You only look once: Unified, real-time object detection. In: **Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition**. 2016.

ROSELL-POLO, J. *et al.* Advances in structured light sensors applications in precision agriculture and livestock farming. **Advances in Agronomy**, v. 133, p. 71-112, 2015.

RUIZ-GARCIA, L.; LUNADEI, L. The role of RFID in agriculture: Applications, limitations and challenges. **Computers and Electronics in Agriculture**, v. 79, n. 1, p. 42-50, 2011.

RUTTER, S. M. A 'smart' future for ruminant livestock production?. **Cattle Practice**, 2012.

SAJWAN, V.; RANJAN, R. Classifying flowers images by using different classifiers in *Orange*. **International Journal of Engineering and Advanced Technology**, v. 8, n. 6, p. 1057-1061, 2019.

SCHNAIDER, M.A *et al.* Vocalization and other behaviors indicating pain in beef calves during the ear tagging procedure. **Journal of Veterinary Behavior**, v. 47, p. 93-98, 2022.

SHANAHAN, C. *et al.* A framework for beef traceability from farm to slaughter using global standards: an Irish perspective. **Computers and Electronics in Agriculture**, v. 66, n. 1, p. 62-69, 2009.

SHEN, W. *et al.* Individual identification of dairy Cows based on convolutional *Neural Networks*. **Multimedia Tools and Applications**, v. 79, p. 14711-14724, 2020.

SHERWIN, C. M. Ear-tag chewing, ear rubbing and ear traumas in a small group of gilts after having electronic ear tags attached. **Applied Animal Behaviour Science**, v. 28, n. 3, p. 247-254, 1990.

SILVI, R. *et al.* Adoption of precision technologies by Brazilian dairy farms: The farmer's perception. **Animals**, v. 11, n. 12, p. 3488, 2021.

SIMONYAN, K. Very deep convolutional networks for large-scale image recognition. **arXiv preprint arXiv:1409.1556**, 2014.

SMITH, G. C. *et al.* Traceability from a US perspective. **Meat Science**, v. 71, n. 1, p. 174-193, 2005.

SONKA, S.; CHENG, Y. Big data: more than a lot of numbers!. **farmdoc daily**, v. 5, n. 201, 2015.

STEEENEVELD, W.; VERNOOIJ, J. C. M.; HOGEVEEN, H. Effect of sensor systems for *Cow* management on milk production, somatic cell count, and reproduction. **Journal Dairy Science**, v.98, p.3896–3905, 2015.

SUN, Shengnan; YANG, Shicai; ZHAO, Lindu. Noncooperative bovine iris recognition via SIFT. **Neurocomputing**, v. 120, p. 310-317, 2013.

SZEGEDY, C. *et al.* Inception-v4, inception-resnet and the impact of residual connections on learning. In: **Proceedings of the AAAI Conference on Artificial Intelligence**. 2017.

TASSINARI, P. *et al.* A computer vision approach based on deep learning for the detection of dairy Cows in free stall barn. **Computers and Electronics in Agriculture**, v. 182, p. 106030, 2021.

TULLO, E.; FINZI, A.; GUARINO, M. Review: Environmetal impact of livrestock farming and precision livestock farming as a mitigation strategy. **Science of the Total Environment**, v. 650, p. 2751–2760, 2019.

TURCO, S. *et al.* Ferramentas para o monitoramento de respostas comportamentais, fisiológicas e de desempenho animal a campo. **Revista Científica de Produção Animal**, v.21, n.1., p.69-75, 2019.

TZANIDAKIS, C. *et al.* An overview of the current trends in precision pig farming technologies. **Livestock Science**, v. 249, p. 104530, 2021.

UNGAR, E. D. *et al.* Inference of animal activity from GPS collar data on free-ranging cattle. **Rangeland Ecology & Management**, v. 58, n. 3, p. 256-266, 2005.

UNIÃO EUROPEIA Communication from the Commission to the European Parliament and the Council. Action Plan Against the Rising Threats from Antimicrobial Resistance. **Comissão Europeia**, 2011.

UWIZEYE, Aimable *et al.* A comprehensive framework to assess the sustainability of nutrient use in global livestock supply chains. **Journal of Cleaner Production**, v. 129, p. 647-658, 2016.

VAISHNAV, D.; RAO, B. Comparison of machine learning algorithms and fruit classification using *Orange* data mining tool. In: **2018 3rd International Conference on Inventive Computation Technologies (ICICT)**. IEEE, 2018. p. 603-607.

VRANKEN, E.; BERCKMANS, D. Precision livestock farming for pigs. **Animal Frontiers**, v. 7, n. 1, p. 32-37, 2017.

WANG, Y. *et al.* E3D: An efficient 3D CNN for the recognition of dairy Cow's basic motion behavior. **Computers and Electronics in Agriculture**, v. 205, p. 107607, 2023.

WILLIAMS, L. R. *et al.* Use of radio frequency identification (RFID) technology to record grazing beef cattle water point use. **Computers and Electronics in Agriculture**, v. 156, p. 193-202, 2019.

WILLIAMS, M.; JAMES, W.; ROSE, M. Variable segmentation and ensemble classifiers for predicting dairy Cow behaviour. **Biosystems Engineering**, v. 178, p. 156-167, 2019.

WU, Q. *et al.* The role of rural infrastructure in reducing production costs and promoting resource-conserving agriculture. **International Journal of Environmental Research and Public Health**, v. 16, n. 18, p. 3493, 2019.

WURTZ, K. *et al.* Recording behaviour of indoor-housed farm animals automatically using machine vision technology: A systematic review. **PloS one**, v. 14, n. 12, p. e0226669, 2019.

XIAO, J. *et al.* Cow identification in free-stall barns based on an improved Mask R-CNN and an SVM. **Computers and Electronics in Agriculture**, v. 194, p. 106738, 2022.

XU, B. *et al.* Automated cattle counting using Mask R-CNN in quadcopter vision system. **Computers and Electronics in Agriculture**, v. 171, p. 105300, 2020.

XU, B. *et al.* CattleFaceNet: A cattle face identification approach based on RetinaFace and ArcFace loss. **Computers and Electronics in Agriculture**, v. 193, p. 106675, 2022.

XU, X. *et al.* Few-shot Cow identification via meta-learning. **Information Processing in Agriculture**, 2024.

YADAV, S.; SHUKLA, S. Analysis of k-fold cross-validation over hold-out validation on colossal datasets for quality classification. In: **2016 IEEE 6th International Conference on Advanced Computing (IACC)**. IEEE, 2016. p. 78-83.

ZAWBAA, H. *et al.* Automatic fruit classification using *Random Forest* algorithm. In: **2014 14th International Conference on Hybrid Intelligent Systems**. IEEE, 2014. p. 164-168.

ZHAO, K.; HE, D. Recognition of individual dairy cattle based on convolutional *Neural Networks*. **Transactions of the Chinese Society of Agricultural Engineering**, v. 31, n. 5, 2015.

ZHAO, J.; LIAN, Q. Compact loss for visual identification of cattle in the wild. **Computers and Electronics in Agriculture**, v. 195, p. 106784, 2022.

ZUCALI, M. *et al.* Management options to reduce the environmental impact of dairy goat milk production. **Livestock Science**, v. 231, p. 103888, 2020.