



LÁZARO HENRIQUE DA SILVA

**DESENVOLVIMENTO DE METODOLOGIAS PARA A
DETECÇÃO DO COMPORTAMENTO INGESTIVO DE
BOVINOS**

LAVRAS – MG

2025

**Ficha Catalográfica elaborada pelo Sistema de Geração
de Ficha Catalográfica da Biblioteca Universitária da UFLA, com
dados informados pelo(a) próprio(a) autor(a).**

Henrique da Silva, Lázaro.

Desenvolvimento de metodologias para a detecção do comportamento ingestivo de
bovinos. / Lázaro Henrique da Silva. - 2025.

125 p. : il.

Orientadora: Marina de Arruda Camargo Danes

Tese (Doutorado) - Universidade Federal de Lavras, 2025.

Bibliografia.

1. Bovinocultura. 2. Ciência de dados. 3. Comportamento animal. 4. Machine
learning. 5. Sensores. I. Danes, Marina de Arruda Camargo . II. Universidade Federal
de Lavras. III. Título.

LÁZARO HENRIQUE DA SILVA

**DESENVOLVIMENTO DE METODOLOGIAS PARA A DETECÇÃO DO
COMPORTAMENTO INGESTIVO DE BOVINOS**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Produção e Nutrição de Ruminantes, para a obtenção do título de Doutor.

Orientador: Dra. Marina de Arruda Camargo Danes

**LAVRAS – MG
2025**

LÁZARO HENRIQUE DA SILVA

**DESENVOLVIMENTO DE METODOLOGIAS PARA A DETECÇÃO DO
COMPORTAMENTO INGESTIVO DE BOVINOS.**

**DEVELOPMENT OF METHODOLOGIES FOR DETECTING THE INGESTIVE
BEHAVIOR OF CATTLE**

Tese apresentada à Universidade Federal de Lavras, como parte das exigências do Programa de Pós-Graduação em Zootecnia, área de concentração em Produção e Nutrição de Ruminantes, para a obtenção do título de Doutor.

Aprovado em 28 de julho de 2025

Dra. Marina de Arruda Camargo Danés, Universidade Federal de Lavras

Dr. Tiago Bresolin, Universidade de Illinois Urbana-Champaign (EUA)

Dra. Erica Beatriz Schultz, Universidade Federal de Viçosa


Dr. Pedro Henrique S. Mazza, Universidade Federal do Norte do Tocantins

Dr. Dr. Gustavo Mazon Correa Alves, University of Wisconsin–Madison (EUA)

Orientadora: Dra. Marina de Arruda Camargo Danes

LAVRAS – MG

2025



Ao meu gato Elfo, que adotei no início do mestrado para ser minha família. Ele enfrentou uma pandemia junto de mim e, infelizmente, faleceu pela maldade humana 15 dias antes de defender meu doutorado. Minha pós-graduação está inteiramente ligada a ele.

Dedico

AGRADECIMENTOS

Primeiramente, agradeço a mim mesmo e aos meus guias espirituais, aqueles que estão sempre comigo. Adorei as almas, Laroyê Exu, Laroyê Pombogira, Okê Caboclos, Oni Beijada, Salve a marujada, Jetuá, Boiadeiros, Optchá. Agradeço também a todos os Orixás, especialmente Iemanjá (Odoiá), Ogum (Ogum Yê) e Oxaguiã (Exê Babá).

À minha esposa, Samira, que tive o prazer de conhecer na reta final do meu doutorado e me deu uma luz única que apenas ela tem. Me trouxe paz, foco e um objetivo juntos. Aos meus pais, Eliane e Arlindo, por todo suporte fornecido até este momento e pelo suporte nos meus próximos passos. Por todos os ensinamentos, conselhos e valores transmitidos. Ao meu irmão Lucas por toda companhia, torcida e conselhos ao longo dos anos, é uma honra ter você como irmão.

À minha orientadora Marina de Arruda Camargo Danes por todos os ensinamentos, conselhos e “puxões de orelha” ao longo dos últimos anos, saiba que hoje escrevo muito mais evoluído como pessoa, zootecnista e pesquisador graças a você.

Ao grupo INPPAR - Inovação, Pesquisa e Pessoas para Alimentação de Ruminantes, por todo suporte na condução do experimento, sem vocês seria impossível realizar esse trabalho. Aprendi muito com vocês e espero que também tenha sido capaz de ensinar algo.

Aos doutores Marina Danes, Tiago Bresolin, Erica Schutz, Nivaldo Karvatte e Adenilson Paiva, por aceitarem o pedido para compor minha banca.

Aos professores e servidores da UFLA, em especial aos professores e servidores do Departamento de Zootecnia, por todo ensinamento e cuidado com os estudantes. Aos meus amigos que cultivei nos últimos anos, em especial a Priscila e a Jucá, que por muitos momentos me ouviram reclamar bastante.

O presente trabalho foi realizado com apoio do Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG) e Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES).

*“Porque teu sonho só sai do travesseiro
se você sair da cama.”*

2ZDinizz

LISTA DE TABELAS

Tabela 1: Revistas que mais publicaram artigos sobre a Zootecnia de Precisão e seu respectivo fator de impacto.	26
Tabela 2: Revistas com maior número de artigos publicados sobre o uso de zootecnia de precisão com foco nas pastagens e em animais a pasto.	40
Tabela 3: Descrição dos comportamentos ingestivos observados em bovinos.	59
Tabela 4: Denominação dos bancos de dados utilizados para duas e três classes. .	60
Tabela 5: Quantidade de dados por classe, isso é comportamento, e quantidade total de dados.....	66
Tabela 6: Hiperparâmetros observados para a classificação de duas classes, Alimentação e Não Alimentação, para os algoritmos Random Forest (RF), Light Gradient Boosting (LGB), K-Nearest Neighbors (KNN) e Rede Neural Artificial (ANN).	67
Tabela 7: Hiperparâmetros observados para a classificação de três classes, Alimentação, Ruminação e Ócio, para os algoritmos Random Forest (RF), Light Gradient Boosting (LGB), K-Nearest Neighbors (KNN) e Rede Neural Artificial (ANN).	68
Tabela 8: Acurácias observadas em alguns artigos sobre a classificação do comportamento de bovinos para diferentes modelos classificadores. Random Forest (RF), Decision Tree (DT), Gradient Boosting (GB), Suport Vector Machine (SVM) e Rede Neural Artificial (ANN).....	69
Tabela 9: Métricas obtidas para cada banco de dados binário, validados pela estratégia Holdout, nos quatro diferentes algoritmos adotados. Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).	70
Tabela 10: Média das métricas observadas nos bancos de dados binário e no banco de dados unificado binário para cada algoritmo adotado e validação Holdout. Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).	73
Tabela 11: Métricas obtidas para cada banco de dados binário e banco de dados unificados binário, validados por validação externa, nos quatro diferentes algoritmos adotados.....	75

Tabela 12: Métricas obtidas para cada banco de dados multiclasse, validados pela estratégia Holdout, nos quatro diferentes algoritmos adotados, sendo eles Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).	77
Tabela 13: Média das métricas observadas nos bancos de dados multiclasse e no banco de dados unificado multiclasse para cada algoritmo adotado e validação Holdout.	79
Tabela 14: Métricas obtidas para cada banco de dados multiclasse e banco de dados unificados multiclasse, validados por validação externa, nos quatro diferentes algoritmos adotados.	80
Tabela 15: Descrição dos comportamentos ingestivos observados em bovinos.....	91
Tabela 16: Limites para a busca por hiperparâmetros para as estratégias de Random Search e Busca Bayesiana.	92
Tabela 17: Quantidade de dados observados para cada Banco de Dados obtido. Considerando quantidade total e quantidade por classe.....	97
Tabela 18: Melhores hiperparâmetros obtidos para cada estratégia de busca por hiperparâmetros.	99
Tabela 19: Parâmetros de desempenho para o modelo treinado com cada um dos melhores hiperparâmetros selecionados.....	99
Tabela 20: Acurácia observada em diferentes artigos que comparam estratégias de busca por hiperparâmetros.....	100
Tabela 21: Métricas de desempenho observadas para as diferentes estratégias de balanceamento de dados e sem balanceamento.	102
Tabela 22: Métricas de desempenho para equipamentos vestidos na nuca e no colar de bovinos para dois grupos de dados, Binário e Multiclasse.	104
Tabela 23: Tem despendido, em porcentagem, para cada comportamento quando expostos a observações contínuas e observações a cada 5 minutos.....	106
Tabela 24: Quantidade total de dados e métricas de desempenho para bancos de dados com observações contínuas versus intervalos de coleta de dados.	107
Tabela 25: Métricas de desempenho do modelo classificadores aplicado a 4 diferentes bancos de dados, divididos por coletas contínuas de dados e intervalos de coleta.	110

LISTA DE FIGURAS

Figura 1: Evolução da quantidade de artigos relacionados a Zootecnia de Precisão publicadas ao longo dos anos	26
Figura 2: Mapa dos países em que os pesquisadores mais publicaram artigos relacionados a Zootecnia de Precisão. Quanto mais intensa a cor, mais publicações.	27
Figura 3: Mapa dos países em que os pesquisadores mais colaboraram entre si para publicaram artigos relacionados a Zootecnia de Precisão.	28
Figura 4: Word Cloud das palavras mais presentes nas keywords dos artigos sobre Zootecnia de precisão.	30
Figura 5: Quantidade de artigos publicados sobre o uso de drones na produção animal ao longo dos anos.	35
Figura 6: Mapa dos países com mais publicações sobre o uso de zootecnia de precisão relacionados ao estresse por calor. Quanto mais intenso a cor, maior o número de publicações.	36
Figura 7: Quantidade de publicações por ano distribuídos entre os cinco países com mais artigos relacionados a detecção de estro.	38
Figura 8: Mapa dos países com mais publicações sobre o uso de zootecnia de precisão para a gestão das propriedades rurais e as colaborações entre os pesquisadores. Quanto mais intenso a cor, maior o número de publicações.	39
Figura 9: Conexões entre as palavras mais comuns encontradas nos artigos sobre o uso de imagens na zootecnia de precisão.	41
Figura 10: Quantidade de artigos publicados por ano sobre o uso de imagens na zootecnia de precisão.	42
Figura 11: Foto do equipamento utilizado, bem como os componentes presentes...	56
Figura 12: Estratégia de validação, adotando um banco de dados para treinamento e o restante para validação.	61
Figura 13: Estratégia de validação externa, adotando como treinamento a unificação “-K” banco de dados e para treinamento o banco de dados “K”.	62
Figura 14: Esquema ilustrativo de uma matriz de confusão.	63
Figura 15: Foto do equipamento utilizado, bem como os componentes presentes...	88
Figura 16: Esquema do local de fixação dos equipamentos vestíveis.	93
Figura 17: Esquema ilustrativo de uma matriz de confusão	95

Figura 18: Representação gráfica de dados referentes a locomoção (Walking), Ócio (Standing) e pastejo (Grazing).	103
Figura 19: Esquema ilustrativo da aplicação dos intervalos de dados ao longo do tempo.	107

SUMÁRIO

1.	INTRODUÇÃO.....	19
2.	OBJETIVOS.....	23
2.1	Objetivo geral	23
2.2	Objetivos específicos	23
3.	ESTADO DA ARTE	25
3.1	Considerações gerais.....	25
3.2	Aplicabilidade	30
3.3	Manejo Sanitário e Saúde	33
3.4	Uso De Drones.....	34
3.5	Estresse Por Calor	36
3.6	Detecção De Estro	37
3.7	Gestão E Tomada De Decisão.....	38
3.8	Pastagens E Animais A Pasto.....	39
3.9	Imagens	40
3.10	Rastreabilidade	43
4.	DESAFIOS	44
4.1	Custos	44
4.2	Privacidade E Segurança Dos Dados	46
4.3	Necessidade De Treinamento E Suporte Adequados	47
4.4	Limitações Técnicas.....	48
4.5	Mudanças De Cultura Dos Produtores.....	49
5.	CLASSIFICAÇÃO DO COMPORTAMENTO INGESTIVO DE BOVINOS COM DADOS HETEROGÊNEOS: UMA ABORDAGEM COM MACHINE LEARNING	51
5.1	Resumo	51
5.2	Introdução	52

5.3 Material E Métodos	55
5.3.1 Instrumentação.....	55
5.3.2 Coletas	56
5.3.4 Observações Visuais.....	58
5.3.5 Aplicação Das Técnicas De Machine Learning	59
5.3.6 Estratégias De Validação	60
5.3.7 Avaliação De Desempenho	62
5.4. Resultado E Discussão	64
5.4.1 Considerações Gerais.....	64
5.4.2 Hiperparâmetros.....	67
5.4.3 Classificação Binaria	69
5.4.4 Classificação Multiclasse	76
5.5. Conclusão	81
6. OTIMIZAÇÃO DE MODELOS CLASSIFICADORES PARA A ZOOTECNIA DE PRECISÃO: HIPERPARÂMETROS, BALANCEAMENTO E OBSERVAÇÕES VISUAIS.....	82
6.1 Resumo	82
6.2 Introdução	83
6.3 material e métodos.....	87
6.3.1 Instrumentação.....	87
6.3.2 Observações Visuais.....	90
6.3.3 Aplicação Das Técnicas De Machine Learning	91
6.3.4 Busca Por Hiperparâmetro	92
6.3.5 Balanceamento Dos Dados.....	92
6.3.6 Local De Fixação.....	92
6.3.7 Intervalo De Captura De Dados	93
6.3.8 Estratégia De Validação E Métricas De Desempenho	94
6.4 Resultado E Discussão	97

6.4.1 Considerações Gerais.....	97
6.4.2 Melhores Hiperparametros.....	98
6.4.3 Balanceamento De Dados	101
6.4.4 Local De Fixação Dos Sensores Vestíveis.....	104
6.4.5 Observações Visuais.....	105
6.4.6 Intervalos De Dados.....	107
6.4.7 Observações Em Horários Fixos.....	109
6.5 Conclusão	111
REFERÊNCIAS	115

RESUMO

A Zootecnia de Precisão tem revolucionado a produção animal ao integrar sensores, ciência de dados e algoritmos de aprendizado de máquina. Contudo, algumas bases metodológicas ainda não foram completamente exploradas. Pensando nisso, este estudo buscou desenvolver e validar metodologias para automatizar a detecção do comportamento ingestivo de bovinos. O presente trabalho utilizou sensores vestíveis do tipo acelerômetro e giroscópio triaxial fixados na nuca e colar dos animais. As coletas de dados ocorreram entre 2023 e 2025, em oito cenários distintos de produção. Foram realizadas observações visuais contínuas, que depois foram manipuladas para simular observações por intervalos de tempo. Os dados foram organizados em nove bancos distintos e posteriormente unificados. Utilizou-se validação Holdout e validação externa. Quatro algoritmos foram comparados: Random Forest (RF), Light Gradient Boosting (LGB), K-Nearest Neighbors (KNN) e Redes Neurais Artificiais (ANN). Três estratégias de busca por hiperparâmetros foram testadas (Random Search, Bayesian Search e Algoritmos Evolutivos), bem como técnicas de balanceamento (SMOTE, ADASYN, NearMiss e Undersampling aleatório). Avaliou-se ainda o impacto de diferentes intervalos de coleta (1s a 60s) e locais de fixação dos sensores. As métricas de desempenho foram Acurácia, Precisão, Recall e F1-Score. Os modelos preditivos apresentaram bom desempenho na classificação dos comportamentos alimentando, ruminando e ócio, com destaque para o algoritmo RF, especialmente em bases binárias. A generalização dos bancos de dados melhorou a acurácia em validação externa, confirmando a hipótese de que algoritmos treinados com dados heterogêneos são mais robustos. A validação Holdout, embora com melhores métricas, superestimou os resultados. Estratégias de balanceamento impactaram o desempenho quando olhamos precisão, recall e F1-Score, mas não a acurácia. Quanto ao local de fixação, sensores na nuca superaram os do colar, principalmente na detecção do comportamento de alimentação. Intervalos maiores entre capturas de dados (até 60s) mantiveram boa performance, indicando uma viabilidade prática. Observações visuais por intervalos de 2 minutos mostraram-se eficazes, poupando esforço do observador sem comprometer a acurácia. O uso combinado dessas metodologias permite avançar na criação de soluções aplicáveis à realidade de campo na pecuária 4.0. Conclui-se que a integração entre sensores, algoritmos otimizados e bases heterogêneas oferece alto potencial para o monitoramento automatizado do comportamento ingestivo de bovinos.

Palavras Chave: Bovinocultura; Ciência de Dados; Comportamento animal; Machine Learning; Sensores.

ABSTRACT


Precision Livestock Farming has revolutionized animal production by integrating sensors, data science, and machine learning algorithms. However, some methodological foundations have not yet been fully explored. With this in mind, this study aimed to develop and validate methodologies for automating the detection of cattle ingestive behavior. This work used wearable sensors, including a triaxial accelerometer and gyroscope, fixed on the animals' neck and collar. Data collection took place between 2023 and 2025 across eight distinct production scenarios. Continuous visual observations were made, which were then manipulated to simulate time-interval observations. The data were organized into nine distinct databases and subsequently unified. Holdout validation and external validation were employed. Four algorithms were compared: Random Forest (RF), Light Gradient Boosting (LGB), K-Nearest Neighbors (KNN), and Artificial Neural Networks (ANN). Three hyperparameter search strategies were tested (Random Search, Bayesian Search, and Evolutionary Algorithms), as well as balancing techniques (SMOTE, ADASYN, NearMiss, and Random Undersampling). The impact of different data capture intervals (1s to 60s) and sensor attachment locations was also assessed. The performance metrics were Accuracy, Precision, Recall, and F1-Score. The predictive models performed well in classifying feeding, rumination, and idling behaviors, with RF standing out, especially in binary datasets. The generalization of the databases improved accuracy in external validation, confirming the hypothesis that algorithms trained on heterogeneous data are more robust. Although Holdout validation yielded better metrics, it overestimated the results. Balancing strategies impacted performance when considering precision, recall, and F1-Score, but not accuracy. Regarding sensor placement, neck-mounted sensors outperformed collar-mounted ones, particularly in detecting feeding behavior. Larger intervals between data captures (up to 60s) maintained good performance, indicating practical feasibility. Two-minute interval-based visual observations proved effective, saving observer effort without compromising accuracy. The combined use of these methodologies allows for progress in creating solutions applicable to the field reality of livestock 4.0. It is concluded that the integration of sensors, optimized algorithms, and heterogeneous datasets offers high potential for the automated monitoring of cattle ingestive behavior.

Keywords: Animal behavior; Cattle; Data Science; Machine Learning; Sensors.

RESUMO INTERPRETATIVO E INFOGRÁFICO

A Zootecnia de Precisão tem revolucionado a produção animal. Porém, ainda há muitas dúvidas sobre a metodologia a ser aplicada. Este estudo propôs comparar diferentes metodologias para a classificação do comportamento ingestivo de bovinos, integrando sensores vestíveis (acelerômetro e giroscópio triaxial), ciência de dados e algoritmos de aprendizado de máquina. As coletas ocorreram entre 2023 e 2025 em oito diferentes cenários produtivos, com dados unificados posteriormente. Observações visuais contínuas serviram como base para simulações de observações por intervalos de tempo, tanto em observações binárias e multiclasse. Utilizou-se validação Holdout e validação externa. Quatro algoritmos foram comparados (RF, LGB, KNN e ANN). Testaram-se três estratégias de busca por hiperparâmetros (Random Search, Bayesian Search e Algoritmos Evolutivos) e quatro técnicas de balanceamento (SMOTE, ADASYN, NearMiss e Undersampling aleatório). Os modelos apresentaram bom desempenho nas métricas de Acurácia, Precisão, Recall e F1-Score, sendo o RF o mais robusto, principalmente com dados heterogêneos e sensores na nuca. A generalização dos bancos melhorou a acurácia na validação externa, enquanto a validação Holdout superestimou os resultados. O balanceamento influenciou métricas específicas, mas não a acurácia geral. Observações visuais por intervalos de até dois minutos mostraram-se eficientes. Intervalos de coleta maiores (até 60s) mantiveram boa performance, indicando viabilidade prática.

Infográfico: Principais resultados encontrados em nossa pesquisa para cada análise realizada. Resultados em negrito e acompanhados do sinal “ • ” apresentaram melhores métricas de desempenho.



IMPACTOS SOCIAIS, TECNOLÓGICOS, ECONÔMICOS E CULTURAIS

O presente trabalho propõe o desenvolvimento de metodologias robustas e concisas voltadas à detecção automatizada do comportamento ingestivo de bovinos, com foco na construção de sistemas preditivos baseados em dados provenientes de sensores vestíveis. A padronização e validação dessas metodologias representam um avanço estratégico para a criação de ferramentas tecnológicas capazes de identificar e classificar, com alta acurácia, distintos padrões comportamentais relacionados à alimentação, ruminação e ócio. A partir dessas informações, torna-se viável inferir indicadores-chave da saúde animal, como distúrbios metabólicos, início de enfermidades, manifestação do estro, limiares produtivos e níveis de bem-estar. Embora o enfoque do presente estudo seja predominantemente investigativo, suas aplicações extrapolam o escopo experimental, oferecendo subsídios científicos e operacionais para pesquisas futuras e para o desenvolvimento de tecnologias emergentes com aplicabilidade direta no ambiente das propriedades rurais. Trata-se de uma contribuição significativa para a promoção da pecuária de precisão no Brasil e em contextos internacionais, alinhando-se diretamente aos Objetivos de Desenvolvimento Sustentável (ODS) da Organização das Nações Unidas — especialmente nos eixos de erradicação da fome e promoção da agricultura sustentável (ODS 2), saúde e bem-estar animal e humano (ODS 3), inovação nos sistemas agroprodutivos (ODS 9) e consumo e produção responsáveis (ODS 12). Adicionalmente, os desdobramentos tecnológicos oriundos desta pesquisa apresentam potencial de impacto direto na melhoria das condições de trabalho no campo, ao viabilizar a automação de processos tradicionalmente laboriosos, mitigar a escassez de mão de obra e ampliar a qualidade de vida dos produtores rurais por meio da adoção de soluções inteligentes e de fácil integração às rotinas de manejo.

SOCIAL, TECHNOLOGICAL, ECONOMIC AND CULTURAL IMPACTS

The present study proposes the development of robust and concise methodologies aimed at the automated detection of ingestive behavior in cattle, with a focus on constructing predictive systems based on data obtained from wearable sensors. The standardization and validation of these methodologies represent a strategic advancement in the creation of technological tools capable of accurately identifying and classifying behavioral patterns related to feeding, rumination, and idleness. From these data, it becomes feasible to infer key indicators of animal health, such as metabolic disorders, early onset of diseases, estrus manifestation, production thresholds, and overall well-being. Although the study adopts a predominantly investigative approach, its applications extend far beyond the experimental domain, offering a solid scientific and operational foundation for future research and the development of emerging technologies with direct applicability in rural environments. This work constitutes a significant contribution to the advancement of precision livestock farming in Brazil and globally, directly supporting the United Nations

Sustainable Development Goals (SDGs) — particularly those related to zero hunger and sustainable agriculture (SDG 2), good health and well-being for animals and humans (SDG 3), innovation in production systems (SDG 9), and responsible consumption and production (SDG 12). Furthermore, the technological outcomes of this research have the potential to directly improve working conditions in rural areas by enabling the automation of traditionally labor-intensive tasks, mitigating labor shortages, and enhancing farmers' quality of life through the adoption of intelligent solutions seamlessly integrated into routine management practices.

1. INTRODUÇÃO

Quando estudamos sobre as três primeiras revoluções industriais, aprendemos sobre as tecnologias aplicadas e seu impacto nos meios de produção, resultando em um aumento na capacidade produtiva do ser humano. Atualmente, estamos vivenciando a quarta revolução industrial, também conhecida como revolução 4.0. Essa nova revolução é caracterizada pela integração das tecnologias desenvolvidas nas revoluções anteriores, como sensores e robótica, com a vasta quantidade de dados que geramos atualmente, conhecida como ciências de dados. Essa combinação resulta na criação de sistemas totalmente automatizados e integrados, capazes de coletar, analisar e utilizar dados para auxiliar nas tomadas de decisão e implementar mudanças recomendadas.

Da mesma forma, a produção animal, e consequentemente a pecuária, também está passando por uma transformação na quarta revolução industrial, com a crescente adoção de novas tecnologias nas propriedades rurais. Esse processo é denominado "produção animal 4.0" ou "pecuária 4.0". Os objetivos dessa transformação são similares aos da indústria, que envolvem a aplicação de tecnologias de automação, ciência de dados, engenharia de software e outros campos, com o intuito de auxiliar os produtores rurais na tomada de decisão e aumentar a lucratividade em suas propriedades.

Outra forma de referenciar a "produção animal 4.0" é através do termo "Zootecnia de precisão". Termo cunhado no final dos anos 90 e início dos anos 2000, derivando do termo em inglês "Precision Livestock Farming", que, por sua vez, tem origem no termo "Precision Agriculture" ou "Precision Farming". Pandorfi et al., (2012) definem o termo como "A maneira de fornecer meios ao produtor para monitorar seus empreendimentos de forma prática e alcançar índices produtivos com base em informações geradas por sistemas especialistas". Enquanto Berckmans, (2014) define a Zootecnia de Precisão como "Uma abordagem de monitoramento e gestão em tempo real de animais de produção, cujo objetivo é melhorar a qualidade de vida dos animais, detectando eventuais problemas para que o produtor possa tomar medidas imediatas. Essa abordagem utiliza tecnologias digitais para monitorar de forma

continua a saúde, o bem-estar e o desempenho dos animais, bem como o impacto ambiental da produção animal."

Diversos processos podem ser automatizados na produção animal 4.0, como a previsão de doenças (Sadeghi et al., 2023), a identificação de cio e parto (Perez Marquez et al., 2023), a determinação do momento ideal de venda (SUNESH et al., 2022), qualidade dos produtos (Liu et al., 2023) entre outros. Uma aplicação interessante é a identificação do comportamento animal (Neethirajan & Kemp, 2021). Na avaliação de comportamento animal, essa automação acontece principalmente pela adoção de sensores vestíveis, como colares e brincos, (Arablouei et al., 2021; Shafiullah et al., 2019) ou por imagem (Arıkan et al., 2023).

Contudo, as bases metodológicas para a realização de pesquisas nessa área ainda não estão bem estabelecidas, havendo escassez de estudos que comparem diferentes procedimentos e metodologias. Essas lacunas de conhecimento acabam atrasando o desenvolvimento de soluções práticas que efetivamente beneficiem os produtores. Gerando apenas soluções eficientes em ambientes acadêmicos e centros de pesquisas.

Alguns autores buscam comparar os diferentes modelos classificadores na classificação do comportamento animal, como Q. T. Nguyen et al., (2020) que compararam os modelos Elastic regression, Suport Vector Machine, Random forest e Neural Network. Contudo, há dois problemas nessas abordagens. A primeira, é que ambas utilizam da validação Holdout e, como demonstrado por Coelho Ribeiro et al., (2021), essa estratégia infla os resultados observados, já que não leva em consideração as inter-relações entre animal, planta e ambiente. O segundo problema é que esses trabalhos utilizam apenas um banco de dados para o treinamento, sem adotar uma visão holística dos procedimentos. Isso faz com que tenhamos algoritmos altamente capacitados para casos únicos, não aplicáveis a outros bancos de dados.

Esse é um problema ainda maior quando buscamos realizar uma validação externa. Esse tipo de avaliação, apesar de extremamente necessário, não foi utilizada em nenhum dos artigos encontrados para a produção animal. Validações externas são capazes de simular a aplicação real de um produto no mercado. Uma forma de contornar isso é generalizar o banco de dados, apresentando ao algoritmo diversas situações divergentes, para que ele possa aprender com o máximo de cenários

possíveis (Hauschild et al., 2022). Assim, nossa hipótese é que a generalização do banco de dados de treinamento irá ampliar a capacidade de classificação do algoritmo ao ser exposto a uma validação externa, em comparação com modelos treinados apenas com um banco de dados e expostos a dados externos. Por outro lado, quando utilizamos uma validação Holdout, acreditamos que a generalização do banco de dados poderá ser inferior as demais.

Ademais, outras dúvidas também não apresentam soluções. Decandia et al., (2018) buscaram entender qual melhor intervalo entre capturas de dados, buscando uma maior economia de bateria e de poder computacional. Os autores identificaram que, até 60 segundos, não há diferença na acurácia dos modelos, logo não é necessário que os sensores captem informações a cada segundo. Porém, esse é o único trabalho encontrado que aborda essa temática.

O balanceamento do banco de dados também é importante para modelos que buscam classificar o comportamento animal, dados desbalanceados podem interferir diretamente na predição dos modelos, pois ao expor o algoritmo a uma classe com maior quantidade de dados, o modelo pode priorizar essa classe. O balanceamento artificial dos dados pode ser realizado principalmente de duas formas distintas. *Undersampling* e *Oversampling*. A primeira é quando parte dos dados da classe majoritária é retirada, de maneira aleatória, igualando a quantidade de dados em todas as classes. A segunda é quando novos dados são gerados ou copiados a partir da classe de menor quantidade de dados, igualando com a classe com maior quantidade de dados.

Por fim, não há um consenso sobre o melhor local de fixação dos sensores. Alguns autores vestem os sensores na nuca dos animais, com auxílio de um cabresto, como Coelho Ribeiro et al., (2021) e Arablouei et al., (2021), enquanto outros optam por fixá-los no pescoço, como Dissanayake et al., (2024) e Mladenova et al., (2024). Nossa hipótese é que sensores vestidos na nuca dos animais apresentem melhores métricas de avaliação, pois esse local garante uma maior amplitude de movimentação da cabeça, essencial para identificar principalmente o comportamento de buscar alimento.

Com base nessas observações, nosso objetivo é comparar diferentes metodologias utilizadas por outros pesquisadores, a fim de identificar aquelas que são

mais eficientes na previsão do comportamento de animal. Além de explorar uma visão mais geral, unificando diversos bancos de dados em um único.

Esta tese propõe uma abordagem integrada e inédita na detecção do comportamento ingestivo de bovinos. Aliando sensores vestíveis, aqui também chamado de equipamento, algoritmos de aprendizado de máquina, estratégias de validação e análises comparativas entre locais de fixação e intervalos de observação. Utilizando bancos de dados heterogêneos, com foco não apenas na acurácia, mas na viabilidade prática. Com isso, esta tese contribui diretamente para a consolidação de metodologias mais realistas, generalizáveis e aplicáveis à realidade do campo.

Nosso projeto é financiado através do edital Nº 001/2022 - Demanda Universal, da Fundação de Amparo à Pesquisa do Estado de Minas Gerais (FAPEMIG). Processo número APQ-01869-22.

2. OBJETIVOS

2.1 Objetivo geral

Desenvolvimento de metodologias básicas e avançadas para a zootecnia de precisão, visando a aplicação e validação de um produto comercial destinado à automação do manejo de bovinos.

2.2 Objetivos específicos

(1) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados **individuais** e validação **Holdout** para a predição dos comportamentos de **“Alimentando”** e **“Não Alimentando”**;

(2) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados **unidos** e validação **Holdout** para a predição dos comportamentos de **“Alimentando”** e **“Não Alimentando”**;

(3) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados **unidos** e validação **Externa** para a predição dos comportamentos de **“Alimentando”** e **“Não Alimentando”**;

(4) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados **individuais** e validação **Holdout** para a predição dos comportamentos de **“Alimentando”**, **“Ruminando”** e **“Ócio”**;

(5) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados

unidos e validação **Holdout** para a predição dos comportamentos de **“Alimentando”, “Ruminando” e “Ócio”**;

(6) avaliar métricas de desempenho para quatro diferentes modelos classificadores, Random Forest (RF), Gradient Boosting (LGB), Redes Neurais Artificiais (ANN) e k-nearest neighbors (KNN) utilizando 9 diferentes bancos de dados **unidos** e validação **Externa** para a predição dos comportamentos de **“Alimentando”, “Ruminando” e “Ócio”**;

(7) testar a aplicabilidade de diferentes estratégias de busca por hiperparâmetros na classificação do comportamento ingestivo de bovinos;

(8) identificar o local mais adequado para a fixação dos sensores vestíveis nos animais, considerando pontos como nuca e colar

(9) avaliar diferentes estratégias de captura de dados ao longo do tempo. Sendo elas 1 segundo, 1 minuto, 5 minutos ou intervalos de 2 minutos;

(10) avaliar o impacto do balanceamento do banco de dados na acurácia da predição do comportamento.

3. ESTADO DA ARTE

3.1 Considerações gerais


Para avaliar o estado da arte do conceito de Zootecnia de Precisão, foi conduzida uma pesquisa bibliográfica abrangente, envolvendo artigos publicados até março de 2023. As análises bibliométricas foram realizadas utilizando o pacote bibliometrix na linguagem de programação R, permitindo um processamento robusto dos dados. Os artigos foram selecionados a partir da base de dados SCOPUS, utilizando a expressão "Precision Livestock," que inicialmente retornou 3.971 publicações.

Contudo, uma parte significativa desses artigos não atendia aos critérios de interesse estabelecidos. Para refinar a seleção, foram aplicadas algumas limitações. Primeiramente, a pesquisa foi restrita às subáreas "Agricultural and Biological Sciences," "Computer Science," "Engineering" e "Veterinary," com o intuito de garantir que os artigos selecionados fossem de relevância direta para o campo da Zootecnia de Precisão. Em seguida, foi realizada uma filtragem quanto ao tipo de documento, selecionando apenas "Article" e "Review," afim de uma análise focada apenas em artigos científicos e revisões especializadas. A terceira limitação envolveu o idioma, considerando apenas publicações em inglês, dada a predominância desta língua nas publicações científicas de alto impacto na área. Adicionalmente, uma leitura rápida dos resumos (abstracts) foi realizada para excluir publicações que não estivessem alinhadas com o tema proposto. Após a aplicação dessas restrições, foram selecionados 1.582 artigos.

O trabalho mais antigo encontrado, de Day, (2005), destaca a relevância das técnicas de automação na agropecuária, abordando como essas práticas podem reduzir desperdícios de insumos, ao mesmo tempo em que atendem à crescente demanda por alimentos seguros, de alta qualidade e a custos mais acessíveis. A análise de Day foca especialmente no campo da engenharia de biossistemas, um dos pilares da Zootecnia de Precisão. No entanto, é relevante notar que a Zootecnia de Precisão só começou a ganhar destaque substancial nos últimos anos, como evidenciado pela sua taxa de crescimento anual de 28,43%. A Figura 1 demonstra claramente esse crescimento, com um aumento modesto nas publicações entre 2005

e 2010, seguido por um crescimento contínuo até 2017, quando houve um salto significativo de 41 publicações naquele ano para 109 em 2018, refletindo o momento de ascensão desta área emergente.

Figura 1: Evolução da quantidade de artigos relacionados a Zootecnia de Precisão publicadas ao longo dos anos



Os 1.582 trabalhos encontrados em nossa busca foram publicados em 323 revistas científicas distintas. Entre essas publicações, algumas revistas se destacam pela quantidade de artigos publicados e pela relevância no campo da Zootecnia de Precisão. As revistas de maior destaque incluem "Computers and Electronics in Agriculture," "Animals," "Journal of Dairy Science" e "Biosystems Engineering." Essas quatro revistas não apenas concentram a maior quantidade de artigos sobre o tema, mas também são as que apresentam os quatro maiores fatores de impacto, conforme demonstrado na Tabela 1.


Tabela 1: Revistas que mais publicaram artigos sobre a Zootecnia de Precisão e seu respectivo fator de impacto.

Revista	Artigos publicados	Fator de impacto
Computers and Electronics in Agriculture	221	46
Animals	181	23
Journal of Dairy Science	75	27
Biosystems Engineering	71	25
Animal	63	20
Sensors	52	21

A China é o país com o maior número de publicações na área de Zootecnia de Precisão, destacando-se por um crescimento impressionante nos últimos anos. Até 2021, a China ocupava a terceira posição no ranking global de países com mais pesquisas na área, ficando atrás dos Estados Unidos e da Bélgica. Contudo, o país superou ambas as nações, apresentando um aumento substancial no número de publicações, alcançando 609 artigos até o momento.

Outros países que também se destacam incluem os Estados Unidos, com 417 publicações, o Reino Unido, com 331, a Bélgica, com 306, e o Brasil, com 260 publicações, conforme ilustrado na Figura 2. Esses resultados são consistentes com as expectativas, uma vez que, com exceção da Bélgica, esses países são tradicionalmente líderes em pesquisa na área de Zootecnia em nível global.

Figura 2: Mapa dos países em que os pesquisadores mais publicaram artigos relacionados a Zootecnia de Precisão. Quanto mais intensa a cor, mais publicações.



Embora a produção de pesquisa em Zootecnia de Precisão seja liderada por esses países, a análise dos países com mais citações revela uma dinâmica intrigante, que contrasta com o ranking dos países com o maior número de publicações. O Reino Unido se destaca em primeiro lugar com 3.263 citações, seguido pela China com 2.727, Países Baixos com 2.218, pelos Estados Unidos com 1.987 e pela Bélgica com 1.968. De forma notável, o Brasil aparece apenas em décimo lugar, com 833 citações. Esse dado sugere que, embora o Brasil tenha uma produção substancial de pesquisas

na área, os estudos originados em outros países têm uma influência maior ou são mais frequentemente citados na literatura científica global. Algo com que os pesquisadores brasileiros precisam se preocupar.

Outro fator que pode explicar isso são as colaborações entre diferentes instituições de ensino. As colaborações entre pesquisadores de diferentes países formam redes complexas, como ilustrado na Figura 3. Essa globalização do tema pode ser explicada pela natureza multidisciplinar da Zootecnia de Precisão, que envolve diretamente tecnologias emergentes, demandando uma colaboração ampla e diversificada. Observa-se uma forte colaboração entre pesquisadores de vários países europeus, além de uma considerável interação entre chineses e americanos. No caso do Brasil, as principais colaborações ocorrem com pesquisadores dos Estados Unidos, do Canadá e de países europeus. Pouca colaboração é realizada com pesquisadores chineses, justamente os que mais produzem artigos sobre a temática. Essa diversidade nas colaborações internacionais ressalta a importância da cooperação global para o avanço do conhecimento na área de Zootecnia de Precisão.

Figura 3: Mapa dos países em que os pesquisadores mais colaboraram entre si para publicaram artigos relacionados a Zootecnia de Precisão.



Dentre os artigos publicados, alguns se destacam significativamente pelo número de citações recebidas. O trabalho mais citado neste contexto é o de Wang et al., (2006), com 833 citações, o que resulta em uma média anual de 49,06 citações. Nesta revisão de literatura, os autores fornecem uma visão abrangente sobre as tecnologias de sensores sem fio e os padrões de comunicação sem fio, apresentando

exemplos de suas aplicações em diversas áreas da agropecuária e da indústria alimentícia, o que contribui para sua alta relevância e influência na área.

O segundo artigo mais citado é também uma revisão sobre a utilização de redes sem fio, mas de uma abordagem mais recente. Jawad et al., (2017) não se concentram diretamente na produção animal, mas sim na agricultura, com foco específico na produção de grãos. No entanto, as tecnologias discutidas por esses autores possuem uma aplicabilidade significativa também na produção animal, ampliando o alcance do estudo. Este artigo acumula 393 citações, com uma taxa de 75,40 citações por ano, refletindo sua relevância e impacto.

Além dos artigos previamente mencionados, é relevante destacar o trabalho de Sharma et al., (2021), uma revisão abrangente sobre a aplicação de tecnologias de inteligência artificial e Internet das Coisas (IoT) na agropecuária. Os autores discutem como a inteligência artificial, a IoT e as tecnologias de blockchain estão sendo exploradas para aprimorar a sustentabilidade na produção animal, com foco em aspectos como hábitos alimentares, padrões de movimento e comportamento dos animais. Este artigo acumula 188 citações, com uma taxa de citações por ano de 62,67.

Outro trabalho significativo é o de Rutten et al., (2013), que revisa o uso de sistemas de sensores para o gerenciamento de saúde em fazendas leiteiras. Os autores exploram quatro aspectos principais: 1) os sistemas de sensores desenvolvidos para detectar problemas como locomoção inadequada, mastite, estro e distúrbios metabólicos; 2) o desempenho desses sistemas de sensores; 3) as ferramentas de suporte à decisão associadas a esses sistemas; e 4) o impacto econômico da utilização desses sistemas no gerenciamento das fazendas. Este estudo foi citado 332 vezes, com uma taxa de 30 citações por ano.

A citação de um artigo é influenciada diretamente por sua visibilidade e acessibilidade, fatores que podem ser otimizados através de várias estratégias, incluindo a escolha cuidadosa de palavras no título, no resumo e nas palavras-chave do artigo. Nesse contexto, termos como "precision livestock farming" se destacam, pois estão presentes em 355 artigos. A Figura 4 ilustra outras palavras-chave relevantes que podem ser utilizadas para aumentar a visibilidade e a acessibilidade

crucial para a compreensão integral das necessidades dos animais e o aprimoramento das práticas de manejo.

Algumas pesquisas com foco no bem-estar emocional dos animais incluem o estudo de Gladden et al., (2020), que investigou o comportamento de brincadeira em bezerros, um indicador importante para avaliar aspectos do bem-estar. Outro trabalho relevante de Gladden et al., (2020) monitorou a frequência respiratória de vacas leiteiras, utilizando este indicador como uma medida de estresse térmico causado pelo calor excessivo. Adicionalmente, (Chung et al., 2022) desenvolveram simulações para otimizar a ventilação em galpões, visando melhorar a temperatura ambiente sem aumentar os custos operacionais.

Uma segunda área de aplicação da Zootecnia de Precisão, ainda a ser explorada, é o monitoramento da qualidade do leite. Embora diversas tecnologias já possam ser utilizadas para automatizar a produção e monitoramento da quantidade de leite, o potencial para a melhoria da qualidade do leite é vasto e ainda não foi totalmente investigado. As aplicações de tecnologias de precisão nesse domínio podem possibilitar a detecção precoce de problemas de saúde nos animais, além de otimizar a qualidade do produto final. Ji et al., (2022) aplicaram a Zootecnia de Precisão na produção de leite, mas seu foco na quantidade de leite produzido, sem dar atenção à qualidade do leite. Em contraste, (Anglart et al., 2021) direcionaram sua pesquisa especificamente para a qualidade do leite, explorando com mais profundidade essa dimensão crucial da produção de laticínios, destacando-se como um exemplo de abordagem mais centrada na melhoria da qualidade do produto.

De maneira semelhante ao monitoramento da qualidade do leite, a qualidade da carne também pode ser acompanhada por meio da Zootecnia de Precisão. A aplicação dessas tecnologias no setor de carne tem o potencial de detectar precocemente problemas de saúde nos animais, melhorar a qualidade do produto final e até mesmo identificar fraudes, especialmente em relação a carnes adulteradas. O uso de Zootecnia de Precisão nesse contexto pode contribuir significativamente para garantir a autenticidade e a segurança alimentar.

Alguns estudos já estão explorando essa possibilidade. Bai et al., (2022), Liu et al., (2023) e Fan et al., (2022) utilizaram técnicas de aprendizado de máquina para detectar adulterações em carnes processadas, um problema muito comum em alguns

países, como a China e Índia. Em paralelo, (Shin et al., 2021) e Pinto et al., (2023) focaram mais especificamente na qualidade da carne, investigando aspectos relacionados à textura, sabor e outros parâmetros essenciais para a avaliação da qualidade, enriquecendo o entendimento sobre como a Zootecnia de Precisão pode aprimorar a produção de carne.

Por fim, o monitoramento da pegada de carbono da pecuária surge como uma área relevante para a aplicação de tecnologias de precisão. A utilização dessas tecnologias no acompanhamento das emissões de gases de efeito estufa tem o potencial de reduzir significativamente a pegada de carbono da pecuária, promovendo melhorias na sustentabilidade ambiental do setor. A implementação de práticas mais sustentáveis é essencial para mitigar os impactos ambientais da produção animal.

Segundo Jiang et al., (2023), o desenvolvimento da Zootecnia de Precisão exige um esforço colaborativo entre pesquisadores, produtores, empresas e governos. Os pesquisadores devem focar em atender às necessidades específicas dos produtores rurais, enfrentando os desafios práticos da produção animal, enquanto os governos podem facilitar a adoção dessas tecnologias por meio de políticas públicas, incentivos financeiros e programas de capacitação para os produtores. Essa abordagem integrada é essencial para acelerar a implementação de soluções inovadoras e sustentáveis na pecuária.

A colaboração entre pesquisadores, empresas e produtores é essencial para a efetiva transferência de tecnologia e a adoção de práticas sustentáveis no setor agropecuário. Essa transferência pode ser facilitada por meio da criação de redes de inovação, organização de eventos tecnológicos, programas de treinamento e o estabelecimento de parcerias público-privadas. No contexto brasileiro, algumas universidades já possuem incubadoras de empresas, que atuam como instrumentos eficazes para promover a troca de conhecimentos entre a academia, as empresas e os produtores rurais, permitindo a implementação prática das inovações.

Por fim, a Zootecnia de Precisão deve ser reconhecida como uma ferramenta crucial para aprimorar a sustentabilidade econômica, social e ambiental da pecuária. Ao integrar tecnologias inovadoras, ela contribui não apenas para a otimização da produção, mas também para a segurança alimentar e a saúde pública, consolidando

seu papel fundamental no avanço do setor agropecuário de forma responsável e sustentável.

Pensando na percepção dos produtores rurais em relação à Zootecnia de Precisão, Gabriel & Gandorfer, (2023) conduziram um estudo de caso em uma região de agricultura de pequena escala no sul da Alemanha, com o objetivo de compreender os padrões de adoção de tecnologias de agricultura de precisão. Os autores observaram que a adoção de tecnologias digitais na agricultura é influenciada por vários fatores, como o tamanho da fazenda, que está diretamente relacionado ao nível de tecnificação da propriedade, os benefícios esperados pelos agricultores e o conhecimento do gerente da fazenda sobre as tecnologias. Esse estudo destaca a importância de direcionar as pesquisas para atender às necessidades reais dos produtores rurais, enfatizando a necessidade de treinamento adequado e demonstrando como a Zootecnia de Precisão pode ser benéfica para as propriedades rurais. Além disso, os autores ressaltam a importância de manter informações atualizadas sobre a adoção de tecnologias, para que recursos financeiros sejam direcionados para pesquisas que realmente impactem a vida dos produtores.

Com o intuito de expandir ainda o conhecimento sobre as diversas aplicações da Zootecnia de Precisão, foi realizada uma pesquisa bibliométrica específica para investigar áreas de interesse dentro da Zootecnia de Precisão. Essa abordagem permitirá uma compreensão mais aprofundada do estado atual da pesquisa relacionada a essas fronteiras do conhecimento. Para realizar essa pesquisa, foi utilizada a extensão bibliometrix na linguagem R. Foram coletados os dados de pesquisa a partir de consultas na base de dados Scopus, utilizando a combinação de palavras-chave "Precision livestock" com termos como "health", "estrus", "heat stress", "image recognition", "traceability", "management", "pasture" e "drone", de acordo com os objetivos específicos de cada consulta. A seleção foi restrita a artigos e revisões de literatura relevantes para a análise, garantindo que as informações obtidas estivessem alinhadas com os objetivos da pesquisa.

3.3 Manejo Sanitário e Saúde

Pesquisas sobre o uso da Zootecnia de Precisão no manejo sanitário e na prevenção de doenças são bastante comuns, dada a importância do impacto

econômico causado por essas enfermidades. Ao buscar especificamente pelo termo "acidose", encontramos 9 artigos, sendo os mais antigos publicados em 2017. Notavelmente, não foram registradas publicações nos anos de 2018 e 2019, mas houve um retorno das publicações em 2020.

Quando realizamos buscas por doenças relacionadas a aves, encontramos apenas dois artigos relevantes. Sadeghi et al., (2023) buscaram identificar doenças por meio de imagens térmicas, enquanto Mahdavian et al., (2021) utilizaram padrões sonoros para o mesmo propósito. Pesquisas relacionadas com a sanidade de aves se mostraram muito relevantes, pois são poucos os artigos publicadores com essa temática, em contraponto ao fato de a carne de aves ser a mais consumida no mundo.

A claudicação foi abordada em 10 trabalhos, com quatro deles publicados em 2022 e seis em 2023. Destaque para o trabalho de Yigit et al., (2022), que utilizou sensores vestíveis do tipo acelerômetro e giroscópio para prever a claudicação em cavalos, demonstrando uma abordagem promissora para a detecção precoce de problemas de locomoção em animais utilizados em competições. Resultando em uma economia gigantesca.


Por fim, a mastite foi tema de 33 artigos publicados, com a primeira publicação datada de 2015, no estudo de Polikarpus et al., (2015). O ano de 2023 se destaca até o momento, com o maior número de publicações, totalizando 9 artigos. Isso reflete a importância contínua da pesquisa na detecção, monitoramento e prevenção dessa doença, que permanece como uma das principais preocupações na saúde de animais de produção.

3.4 Uso De Drones

O uso de drones, embora amplamente comercializado e aplicado em plantações para diversas finalidades só está sendo explorado na produção animal recentemente. Na pesquisa realizada, foram identificados 24 artigos com foco nessa abordagem. É interessante notar que, de maneira semelhante aos artigos sobre manejo sanitário e saúde animal, a maioria desses estudos foi publicada nos últimos anos, com seis publicações em 2021, cinco em 2022 e cinco em 2023, conforme ilustrado na Figura 5. Esse aumento recente na pesquisa e aplicação de drones na produção animal sugere um crescente reconhecimento do potencial dessa tecnologia

para otimizar diversos aspectos da produção, incluindo o monitoramento de rebanhos, a avaliação do estado das pastagens, e a detecção de problemas de saúde nos animais.

Figura 5: Quantidade de artigos publicados sobre o uso de drones na produção animal ao longo dos anos.



Sobre o uso de drones na produção animal, os dois trabalhos mais citados são os de Eikelboom et al., (2019) e Herlin et al., (2021). No primeiro estudo, os pesquisadores tinham como objetivo realizar a contagem de animais a partir de imagens capturadas por drones. Embora essa técnica seja aplicável para a contagem de animais a pasto, o foco principal da pesquisa estava na contagem de animais na vida selvagem. O segundo trabalho descreve como os drones podem ser utilizados para identificar o comportamento dos animais em pastagens, proporcionando uma compreensão mais detalhada dos padrões de comportamento dos animais em seu ambiente natural.


Além desses, destaco os trabalhos de Soares et al., (2021) e (B. Xu et al., 2020), que também realizaram a contagem de animais em pastagens utilizando imagens capturadas por drones. Esses estudos demonstram a utilidade crescente dessa tecnologia no monitoramento eficiente de rebanhos em ambientes abertos,

como pastagens, o que pode resultar em ganhos significativos em termos de manejo, rastreabilidade e bem-estar animal.

3.5 Estresse Por Calor

O estresse por calor é abordado em 52 artigos de pesquisa, sendo um tema de grande relevância na Zootecnia de Precisão, especialmente no contexto do impacto ambiental na produção animal. O Brasil destaca-se como o país mais proeminente nesse campo, com autores brasileiros contribuindo em 26 dessas publicações, seguido pelos Estados Unidos, Itália e China, conforme ilustrado na Figura 6. Um aspecto notável são as colaborações entre pesquisadores de diferentes países nesse tema. Os pesquisadores brasileiros demonstram uma forte colaboração com seus pares norte-americanos, o que pode refletir o interesse compartilhado e a troca de conhecimentos sobre a gestão do estresse térmico na pecuária. Por outro lado, os pesquisadores chineses tendem a colaborar preferencialmente com pesquisadores belgas e australianos, indicando um padrão de colaboração intercontinental, que amplia a troca de abordagens e soluções para mitigar o impacto do calor nas condições de criação de animais.

Figura 6: Mapa dos países com mais publicações sobre o uso de zootecnia de precisão relacionados ao estresse por calor. Quanto mais intenso a cor, maior o número de publicações.




Embora o Canadá não seja tradicionalmente associado ao estresse por calor devido ao seu clima frio, suas pesquisas se destacam no campo, sendo as mais citadas, com um total de 134 citações. Esse destaque se deve, em grande parte, ao trabalho de Laberge & Rousseau, (2017), que é o artigo mais citado da área, com impressionantes 100 citações, consolidando-se como uma referência importante no estudo do estresse térmico na produção animal. Outro artigo que merecem destaque devido ao número significativo de citações são os de Abeni & Galli, (2017), com 42 citações. Curiosamente, ambos os artigos mais citados foram publicados em 2017, um ano em que foram registrados cinco artigos sobre Zootecnia de Precisão relacionados ao estresse por calor. Antes de 2017, apenas dois artigos haviam sido publicados sobre esse tema. No entanto, após 2017, o número de artigos aumentou significativamente, com 35 publicações adicionais.

3.6 Detecção De Estro

A detecção do estro é de extrema importância para o manejo reprodutivo eficaz do rebanho, pois permite otimizar o tempo de inseminação e melhorar as taxas de fertilidade. No entanto, apesar de sua relevância, há poucos artigos publicados sobre esse tema. Em nossa pesquisa, foram identificados 34 artigos focados na detecção do estro, sendo notável que 11 deles foram publicados em 2023.

Um aspecto que merece destaque é a contribuição dos Estados Unidos para essa linha de pesquisa. Até 2019, não havia registros de publicações sobre a detecção do estro provenientes dos Estados Unidos. No entanto, a partir desse ano, houve um aumento substancial nas publicações, com 17 artigos registrados em 2019 e uma média de 20 artigos por ano desde então, conforme ilustrado na Figura 7. Esse crescimento significativo reflete o crescente e contínuo interesse dos pesquisadores norte-americanos nesse campo, evidenciando uma intensificação dos esforços para aprimorar as técnicas de detecção do estro e, assim, otimizar os programas de reprodução animal.

Figura 7: Quantidade de publicações por ano distribuídos entre os cinco países com mais artigos relacionados a detecção de estro.



3.7 Gestão E Tomada De Decisão


Pesquisas relacionadas à gestão e à tomada de decisão na Zootecnia de Precisão abrange uma vasta gama de tópicos e interesses. Em nossa pesquisa, encontramos um total de 586 artigos com esse propósito. Contudo, é importante destacar que o termo "gestão" engloba uma ampla variedade de áreas, refletindo a diversidade de aspectos que envolvem a administração eficaz das propriedades rurais e o manejo de rebanhos.

Dentro desse contexto, é possível identificar estudos que buscam prever informações específicas da propriedade, como no trabalho de (Aiken et al., 2019), e pesquisas voltadas para a sobrevivência do rebanho, como demonstrado por van der Heide et al., (2019). Além disso, o monitoramento da ordenha, como ilustrado por J. Wang et al., (2022), a previsão do consumo de recursos como luz e água, conforme abordado por Shine et al., (2018), e a identificação do momento ideal para a venda de animais, como discutido por Sunesh et al., (2022), são exemplos adicionais de áreas relevantes de pesquisa sob o tema da gestão na pecuária de precisão.

De maneira geral, os Estados Unidos lideram as pesquisas relacionadas às técnicas de automação da gestão e tomada de decisão, seguidos pela China, Austrália, Inglaterra e Brasil, que completam o top 5 em termos de produção científica nessa área. Quanto às redes de colaboração entre pesquisadores, observa-se que

essas colaborações são complexas e envolvem pesquisadores de diversos países, com destaque para a interação entre países europeus, China, EUA, Austrália e Brasil. Essa dinâmica de colaboração internacional demonstra a natureza global da Zootecnia de Precisão e a importância de parcerias transnacionais, como ilustrado na Figura 8.

Figura 8: Mapa dos países com mais publicações sobre o uso de zootecnia de precisão para a gestão das propriedades rurais e as colaborações entre os pesquisadores. Quanto mais intenso a cor, maior o número de publicações.



3.8 Pastagens E Animais A Pasto

Assim como na gestão e tomada de decisão, a pesquisa relacionada a pastagens na Zootecnia de Precisão abrange uma ampla gama de objetivos e aplicações. Além da contagem de animais a pasto com o uso de drones, como demonstrado por B. Xu et al., (2020), também existem estudos que visam prever a oferta de forragem, como o trabalho de Shafiullah et al., (2019), prever o comportamento ingestivo dos animais Romanzini et al., (2022), classificar a qualidade da forrageira Raynor et al., (2021), identificar a frequência e a quantidade de excrementos produzidos Williams & Zhan Lai, (2022), entre outras abordagens. Essa diversidade de objetivos de pesquisa ilustra a versatilidade e a relevância das técnicas de Zootecnia de Precisão na gestão eficiente das pastagens, contribuindo para um manejo mais sustentável e produtivo.

Foram identificados 160 artigos relacionados ao uso da Zootecnia de Precisão em animais a pasto em nossa pesquisa. É interessante notar que, até o ano de 2014,

o número de publicações nessa área foi praticamente insignificante em comparação com o número de publicações após esse período. O pico de publicações ocorreu em 2022, com um total de 27 artigos. A revista mais relevante nesse contexto foi a *Computers and Electronics in Agriculture*, conforme indicado na Tabela 2, onde podemos ver também outras revistas de interesse.


Tabela 2: Revistas com maior número de artigos publicados sobre o uso de zootecnia de precisão com foco nas pastagens e em animais a pasto.

Revista	Artigos publicados
"Computers and Electronics in Agriculture"	11
"Animal"	7
"Animal Production Science"	7
"Animals"	7
"Applied Animal Behaviour Science"	6
"Remote Sensing"	5
"Livestock Science"	4
"Rangeland Ecology and Management"	4

3.9 Imagens


O uso de imagens para resolver uma variedade de problemas em propriedades rurais representa uma abordagem poderosa que integra aspectos tanto da produção animal quanto da ciência da computação. A Figura 9, que busca unir os termos mais comuns encontrados nesses artigos, ilustra claramente essa conexão entre essas duas áreas do conhecimento. Essa abordagem destaca como o uso de imagens — seja por meio de drones, câmeras térmicas ou outras tecnologias de captura — pode ser uma ferramenta valiosa para solucionar diversos problemas, como a contagem de animais, monitoramento da saúde e bem-estar, análise da qualidade da forragem e outros aspectos críticos da gestão rural. Ao integrar essas tecnologias no manejo diário, é possível otimizar a produção, melhorar a eficiência das operações e contribuir para práticas mais sustentáveis no campo.

Figura 9: Conexões entre as palavras mais comuns encontradas nos artigos sobre o uso de imagens na zootecnia de precisão.



Com o avanço da computação, o uso de imagens para detectar características importantes na Zootecnia tem se tornando cada vez mais comum. Essa tendência é evidenciada pelo aumento exponencial no número de publicações nos últimos anos, como demonstrado na Figura 10. O uso de tecnologias de imagens, como câmeras de alta resolução, drones e imagens térmicas, tem proporcionado uma nova perspectiva no monitoramento da saúde, comportamento, e produtividade dos animais. Isso também está atrelado ao crescimento do poder computacional nos últimos anos, que possibilita análises mais complexas, como é o caso de imagens, além do crescente reconhecimento das vantagens dessa abordagem, que oferece soluções mais precisas e eficientes para a gestão das propriedades rurais.

Figura 10: Quantidade de artigos publicados por ano sobre o uso de imagens na zootecnia de precisão.



O primeiro artigo a empregar imagens para essa finalidade foi proposto por Kim et al., (2005) que visava a identificação de bovinos da raça Wagyu. Esse trabalho pioneiro marcou o início do uso de imagens na Zootecnia de Precisão, mas após essa publicação, houve um período de espera de vários anos até que novos artigos sobre o tema fossem publicados. A maioria dos artigos subsequentes se concentrou na identificação dos animais, como demonstrado pelos estudos de Salau & Krieter, (2020) e Zhang & Mani, (2023). No entanto, alguns estudos mais recentes estão avançando em direção a aplicações práticas de predição utilizando imagens. Além dos trabalhos mencionados de Bai et al., (2022), Liu et al., (2023) e Fan et al., (2022), que abordam a detecção de adulterações em carnes processadas, outros estudos notáveis incluem o trabalho de (Salau et al., 2020), que busca identificar partes específicas do corpo dos animais, Koskela et al., (2022), que foca na identificação do comportamento animal por meio de análise de imagem, e Fuentes et al., (2023), que propõe a detecção da idade e das condições de bem-estar dos animais.

O artigo mais relevante encontrado em nossa busca foi a revisão de Morota et al., (2018), com 108 citações, seguida de outra revisão, a de (Benjamin & Yik, 2019), com 99 citações. O primeiro artigo que não é uma revisão a figurar entre os mais

citados é o trabalho de Spoliansky et al., (2016), com 90 citações. Nesse estudo, os autores buscaram automatizar a classificação do escore de condição corporal de bovinos utilizando imagens obtidas com uma câmera Kinect.

3.10 Rastreabilidade

A rastreabilidade dos produtos animais desempenha um papel importante na garantia da segurança alimentar, permitindo a identificação clara da origem dos produtos e assegurando a qualidade e segurança ao consumidor. No entanto, foi identificado um número limitado de artigos com essa temática, totalizando 28, dos quais 21 foram publicados após 2015.

É interessante notar que, apesar da relevância do Brasil na produção animal, nenhum artigo foi encontrado com a colaboração de pesquisadores brasileiros nesse campo, o que é uma lacuna de participação em pesquisas focadas na rastreabilidade de produtos animais. Em contrapartida, os países com o maior número de publicações sobre esse tema são a China, com 8 artigos, seguidos pelos Estados Unidos, França, Espanha, Alemanha e Austrália, com 5 artigos publicados por cada.

4. DESAFIOS

Apesar dos notáveis avanços nos últimos anos, ainda existem desafios significativos que dificultam uma maior adoção da Zootecnia de Precisão pelos produtores rurais. Bewley et al., (2015) e Berckmans, (2014) destacam algumas limitações importantes, como os custos associados à implementação dessas tecnologias, preocupações com a privacidade e segurança dos dados, a necessidade de uma mudança cultural por parte dos produtores, a demanda por treinamento contínuo e as limitações técnicas relacionadas aos animais, às fazendas e ao ambiente de produção. Esses fatores contribuem para a resistência à adoção de novas tecnologias, apesar de seus potenciais benefícios.

Além dessas barreiras, Jiang et al., (2023) acrescentam a necessidade de fortalecer a aplicação de tecnologias na indústria pecuária, desenvolvendo produtos mais robustos e adequados às realidades do campo. Essas questões são corroboradas por N. Wang et al., (2006) e Sharma et al., (2021), que também identificam essas dificuldades como desafios persistentes ao longo do tempo, indicando que a adoção da Zootecnia de Precisão exige uma abordagem integrada e uma superação contínua dessas limitações para ser bem-sucedida. Esses obstáculos evidenciam a complexidade da transição para práticas de Zootecnia de Precisão e ressaltam a necessidade de políticas públicas, apoio técnico e capacitação para mitigar essas dificuldades e acelerar a adoção de tecnologias no campo.

4.1 Custos

Os custos associados à implementação da Zootecnia de Precisão ainda representam uma barreira significativa para os produtores rurais, abrangendo tanto os custos de aquisição de hardware quanto, em alguns casos, de software, com pagamentos únicos ou por mensalidade. Bewley et al., (2015) argumentam que a tecnologia de monitoramento de precisão pode ser cara, e os produtores precisam realizar uma análise cuidadosa dos custos e benefícios antes de tomar decisões de investimento em novas tecnologias. No entanto, existem várias maneiras de mitigar esses custos e tornar as tecnologias mais acessíveis aos produtores rurais.

Uma das estratégias que pode contribuir para a redução dos custos é a economia de escala. À medida que mais produtores adquirem esses equipamentos, os custos tendem a diminuir. Isso ocorre devido à estrutura de custos das fábricas que produzem esses equipamentos, que envolvem custos fixos (aqueles que não variam com a quantidade produzida) e custos variáveis (relacionados à fabricação do hardware). Quanto maior a produção, mais esses custos fixos são diluídos, resultando em uma redução do custo unitário. Além disso, a entrada de outras empresas no mercado pode gerar concorrência, o que pressiona as empresas a reduzir os custos de produção e, por consequência, o custo dos produtos. Assim, a competitividade no mercado de tecnologia de Zootecnia de Precisão pode beneficiar os produtores, tornando as tecnologias mais acessíveis ao longo do tempo.

Outra estratégia importante é incentivar o desenvolvimento de alternativas que possam resolver os mesmos problemas de forma mais eficiente e econômica. Nem sempre a tecnologia inicialmente desenvolvida para atender a uma necessidade específica será a opção mais acessível. Nesse sentido, financiar e apoiar pesquisas e desenvolvimentos tecnológicos pode estimular a criação de soluções alternativas que sejam mais econômicas e igualmente eficazes.

Uma terceira estratégia envolve o desenvolvimento de produtos multifuncionais, que podem resolver uma gama mais ampla de problemas em uma propriedade rural. Isso permitiria que os produtores adquirissem apenas um equipamento para atender a diversas necessidades, conforme sugerido por (N. Wang et al., (2006)). No entanto, as empresas podem hesitar em seguir essa abordagem, já que lucram com a venda de produtos separados para necessidades específicas.

Além disso, incentivos fiscais por parte do governo, como linhas de crédito ou isenções fiscais para produtores rurais ou empresas que desenvolvem tecnologias de Zootecnia de Precisão, podem ser uma solução viável e eficaz. Tais incentivos podem ser temporários, até que as tecnologias se tornem mais amplamente adotadas.

Sharma et al., (2021) apresentam alternativas adicionais interessantes, como o uso de tecnologias de código aberto, que são desenvolvidas por comunidades de desenvolvedores e disponibilizadas gratuitamente para uso e modificação. Além disso, sugerem o uso de hardwares de baixo custo, como o Raspberry Pi, o que poderia contribuir para a redução dos custos de hardware — uma proposta também

defendida por N. Wang et al., (2006). Outro avanço sugerido é a utilização de soluções de IoT baseadas em nuvem, que permitem aos produtores armazenar e processar dados de sensores em servidores remotos, em vez de investir em infraestrutura local.

Por fim, Bewley et al., (2015) sugerem que os fabricantes de tecnologias aplicáveis no campo, bem como consultores, desenvolvam estratégias para promover a adoção dessas tecnologias nas propriedades rurais. Isso inclui a realização de análises de investimento para garantir que a tecnologia seja adequada às necessidades específicas de cada fazenda. Esse enfoque pode contribuir para uma tomada de decisão mais informada por parte dos produtores rurais, permitindo que percebam o valor da tecnologia em vez de apenas focarem no custo inicial.

4.2 Privacidade E Segurança Dos Dados

Uma das maneiras de reduzir os custos relacionados à Zootecnia de Precisão é optar pelo armazenamento e análise de dados na nuvem, em vez de investir em infraestrutura local. Embora essa abordagem ofereça vantagens significativas em termos de custos, flexibilidade e escalabilidade, ela pode apresentar riscos para a segurança e a privacidade dos dados. A implementação de tecnologias de monitoramento de precisão deve, portanto, ser acompanhada de medidas adequadas para garantir a proteção dos dados coletados, uma vez que esses dados frequentemente contêm informações sensíveis relacionadas à produção animal e à propriedade rural.

Sharma et al., (2021) e N. Wang et al., (2006) sugerem algumas soluções eficazes para mitigar esses riscos. A primeira estratégia é a implementação de criptografia de dados, uma técnica essencial que permite proteger as informações sensíveis por meio de codificação, tornando-as ilegíveis para qualquer pessoa não autorizada. Isso é particularmente importante para dados relacionados à saúde dos animais, produção e uso de recursos, que devem ser protegidos para garantir a privacidade dos produtores.

Outra solução proposta é o uso de redes privadas virtuais (VPNs), que garantem a segurança dos dados dos agricultores, especialmente aqueles em áreas rurais que necessitam de acesso à internet para transferir dados. As VPNs criam uma

conexão segura e criptografada entre os dispositivos do agricultor e a nuvem, o que dificulta a interceptação de dados durante a transmissão.

Além disso, é fundamental utilizar firewalls e software antivírus, ferramentas essenciais para proteger os sistemas de computadores de ataques cibernéticos. Embora frequentemente negligenciados, esses sistemas desempenham um papel crucial na defesa contra acessos não autorizados e malwares que podem comprometer a segurança dos dados.

Por fim, é recomendável que os produtores rurais optem por soluções de IoT e serviços em nuvem fornecidos por empresas respeitáveis e que conduzam testes de segurança regulares. Empresas que investem em segurança cibernética e têm uma boa reputação no mercado podem garantir que os dados coletados sejam tratados com o mais alto nível de segurança, oferecendo tranquilidade aos agricultores quanto à integridade e confidencialidade das informações.

4.3 Necessidade De Treinamento E Suporte Adequados

Para que as soluções tecnológicas funcionem plenamente, é fundamental que os produtores recebam treinamento e suporte adequados para utilizar eficazmente a tecnologia de monitoramento de precisão e interpretar os dados coletados. Isso é particularmente importante, pois o uso inadequado dessas tecnologias pode resultar em uma coleta de dados ineficiente, comprometendo a análise e, conseqüentemente, a tomada de decisões. Além disso, um bom entendimento da tecnologia é essencial para maximizar os benefícios e evitar investimentos mal direcionados.

É igualmente importante que os produtores recebam informações sobre as tecnologias antes de adquiri-las, uma vez que isso pode despertar seu interesse e motivá-los a investir nesses produtos. Essa conscientização prévia ajuda a criar uma base sólida de compreensão e expectativas realistas sobre o que as tecnologias podem oferecer.

Conforme observado por Sharma et al., (2021), fornecer treinamento adequado aos agricultores é essencial para aprimorar suas habilidades técnicas e garantir sua alfabetização digital. Obviamente, não é esperado que os produtores rurais sejam capazes de gerar códigos de programação. O mínimo entendimento de como usar as

tecnologias é o suficiente. Isso não só permite que os produtores operem as tecnologias com mais confiança, mas também garante que possam interpretar os dados de maneira eficaz, o que é crucial para a tomada de decisões informadas.

Além disso, é de suma importância que as empresas e pesquisadores se concentrem no desenvolvimento de produtos de fácil utilização. N. Wang et al., (2006) também enfatizam a importância do treinamento contínuo dos usuários e a facilidade de utilização dos produtos finais, sugerindo ainda a disponibilização de manuais e tutoriais, o que oferece uma forma prática e acessível para os produtores consultarem quando necessário.

Por fim, Bewley et al., (2015) propõem que os fabricantes de tecnologia e os pesquisadores colaborem diretamente com os usuários finais durante o desenvolvimento do produto e após a sua adoção, a fim de minimizar as frustrações relacionadas ao suporte técnico e treinamento inadequados. Essa colaboração contínua permite ajustar os produtos às necessidades reais dos produtores rurais. N. Wang et al., (2006) também apoiam esse conceito, ressaltando a importância de se envolver com os feedbacks dos clientes para promover a melhoria contínua dos produtos, sempre com o foco nas necessidades do produtor rural. Essa abordagem colaborativa é fundamental para garantir que a tecnologia seja eficaz e acessível, maximizando seu impacto positivo na gestão da propriedade rural.

4.4 Limitações Técnicas

Numerosas propriedades rurais, muitas vezes com vastas extensões de terra ou localizadas em regiões de difícil acesso, enfrentam limitações técnicas que dificultam a aplicação da Zootecnia de Precisão. Tais limitações podem se manifestar em conexões problemáticas e demoras no suporte técnico, o que, por sua vez, pode resultar em prejuízos consideráveis para os produtores rurais. Além disso, desafios técnicos inerentes à produção animal, como o consumo de energia pelos equipamentos, também são fatores que precisam ser considerados. No caso de sensores vestíveis, por exemplo, a necessidade de troca de baterias pode representar um manejo adicional, especialmente em propriedades mais distantes, o que gera custos e trabalho extra para os produtores. Além disso, os sensores vestíveis devem

ser suficientemente robustos para suportar condições climáticas adversas e o desgaste, o que muitas vezes entra em conflito com a natureza das novas tecnologias, que tendem a ser mais delicadas.

Uma possível solução para essas barreiras seria o desenvolvimento de soluções tecnológicas que operem efetivamente em áreas rurais com conectividade limitada à internet. Para isso, o uso de tecnologias de comunicação de baixa potência pode ser uma alternativa viável, permitindo a transmissão de dados mesmo em locais com cobertura de rede limitada. Além disso, a exploração de fontes renováveis de energia, como a solar, ou a redução do consumo de energia dos dispositivos, sem comprometer a qualidade dos dados coletados, também pode ser uma abordagem vantajosa, como sugerido por Sharma et al., (2021). Essas soluções podem ajudar a minimizar os custos operacionais e aumentar a autonomia das propriedades rurais, além de promover a sustentabilidade.

Em relação ao suporte técnico, uma solução prática seria a oferta de serviços online, o que possibilita superar as dificuldades de acesso a algumas propriedades rurais, caso a propriedade conte com acesso à internet. Isso evita que os produtores percam tempo e recursos com deslocamentos ou com a espera por assistência presencial, conforme destacado por (N. Wang et al., (2006). O suporte online também pode ser mais ágil e eficiente, contribuindo para a resolução rápida de problemas e para o contínuo aprendizado dos produtores.

Por fim, N. Wang et al., (2006) sugerem que a avaliação das limitações técnicas existentes deve ser o ponto de partida para buscar soluções adequadas e planejar a implantação da Zootecnia de Precisão de forma gradual e escalonada. Essa abordagem visa minimizar os riscos e maximizar os benefícios da adoção da tecnologia, permitindo que os produtores rurais superem as dificuldades iniciais e aproveitem ao máximo o potencial da Zootecnia de Precisão em suas operações.

4.5 Mudanças De Cultura Dos Produtores

Uma das principais barreiras à adoção de novas tecnologias nas propriedades rurais é a resistência dos produtores à mudança. Esse receio pode ser impulsionado por diversos fatores, incluindo o medo de não conseguir aprender as habilidades digitais necessárias, a crença de que os métodos tradicionais são mais eficazes ou a

apreensão de que as tecnologias possam substituir os trabalhadores ou aumentar suas responsabilidades, tornando suas rotinas diárias mais complicadas.

As estratégias para atenuar essa barreira são semelhantes àquelas voltadas para a necessidade de treinamento e suporte adequados. De fato, o fornecimento de treinamento contínuo e suporte técnico eficaz é uma das estratégias mais viáveis para reduzir a resistência dos produtores. O treinamento não apenas ajuda os produtores a se familiarizarem com as tecnologias, mas também desperta seu interesse, demonstrando como essas inovações podem ser benéficas para suas operações, como destacado por Sharma et al., (2021).

Além disso, é crucial que as tecnologias sejam desenvolvidas de maneira a serem de fácil utilização, o que pode reduzir a percepção de complexidade e facilitar a adoção pelos produtores. Produtos com interfaces intuitivas e sistemas de fácil navegação têm maior chance de serem bem recebidos e utilizados, especialmente por aqueles que não possuem um forte conhecimento técnico.

(Bewley et al., (2015) e N. Wang et al., (2006) recomendam, ainda, a realização de pesquisas abrangentes para identificar as reais necessidades dos produtores rurais. Isso evita que os produtos causem frustrações e garante que as tecnologias sejam desenvolvidas de acordo com as exigências práticas do campo. Além disso, essas pesquisas podem fornecer insights valiosos para as empresas, que podem usá-los em suas estratégias de marketing para promover de maneira mais eficaz as tecnologias, destacando os benefícios reais para os produtores e aumentando a probabilidade de adoção das soluções tecnológicas. Essa abordagem baseada nas necessidades do usuário final é essencial para superar a resistência à mudança e fomentar uma maior aceitação das inovações.

5. CLASSIFICAÇÃO DO COMPORTAMENTO INGESTIVO DE BOVINOS COM DADOS HETEROGÊNEOS: UMA ABORDAGEM COM MACHINE LEARNING

5.1 Resumo

Este capítulo avaliou a eficácia de modelos preditivos com base em dados heterogêneos e diferentes estratégias de validação. O estudo utilizou sensores vestíveis com acelerômetros e giroscópios triaxiais, registrando movimentos de bovinos em oito sistemas de produção distintos. Foram realizadas observações visuais contínuas, que serviram como rótulo para os dados. Oito bancos de dados foram organizados com registros dos comportamentos “Alimentando”, “Ruminando” e “Ócio”, que foram unidas posteriormente em “Não Alimentando”. Aplicaram-se quatro algoritmos de classificação Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN), K-Nearest Neighbors (KNN) para duas abordagens: classificação binária (alimentando vs. não alimentando) e multiclasse (alimentando, ruminando, ócio). A validação dos modelos foi feita por Holdout e validação externa. As métricas de avaliação utilizadas incluíram acurácia, precisão, recall e F1-score. Os modelos RF e LGB destacaram-se com os melhores resultados médios, especialmente na classificação binária com validação externa, evidenciando maior capacidade de generalização. A unificação dos bancos elevou a acurácia dos modelos em ambientes externos, reforçando a importância da heterogeneidade dos dados no treinamento. A validação Holdout apresentou métricas superiores, porém superestimadas quando comparadas à validação externa, sugerindo menor realismo para uso prático. Na classificação multiclasse, o desempenho geral caiu, sendo o comportamento de ócio o mais difícil de prever. Ainda assim, modelos como RF mantiveram boa robustez. O uso de bancos heterogêneos, estratégias mais realistas de validação e escolha criteriosa do algoritmo mostraram-se essenciais para melhorar a aplicabilidade prática desses modelos em sistemas reais de produção. Conclui-se que modelos treinados com dados diversos e validados externamente são mais confiáveis para aplicação no campo.

5.2 Introdução

Nas últimas décadas, a produção animal tem passado por transformações significativas, impulsionadas pela convergência entre avanços tecnológicos e a crescente demanda por sistemas de produção mais eficientes e sustentáveis. Tal evolução é embasada na chamada “Quarta Revolução Industrial”, que representa uma nova era de integração entre sistemas, tecnologias de automação e ciência de dados (Kraft et al., 2022; Morrone et al., 2022). No setor agropecuário, esse movimento culminou no conceito de “Pecuária 4.0”, “Zootecnia de Precisão” ou “Precision Livestock Farming”, uma abordagem interdisciplinar que envolve o uso de sensores, algoritmos, plataformas de integração de dados e sistemas de apoio à decisão.

Berckmans, (2014) define a Zootecnia de Precisão como "Uma abordagem de monitoramento e gestão em tempo real de animais de produção, cujo objetivo é melhorar a qualidade de vida dos animais, detectando eventuais problemas para que o produtor possa tomar medidas imediatas. Essa abordagem utiliza tecnologias digitais para monitorar de forma contínua a saúde, o bem-estar e o desempenho dos animais, bem como o impacto ambiental da produção animal.". Assim, podemos definir a Zootecnia de Precisão como o monitoramento em tempo real, a automação de processos e a tomada de decisões baseada em dados, com vistas à melhoria da produtividade, bem-estar animal e sustentabilidade ambiental.

Dentre as aplicações práticas da Zootecnia de Precisão, destaca-se a identificação automatizada de comportamentos animais, especialmente aqueles relacionados à ingestão de alimentos, como pastejo, ruminação e períodos de ócio (Morrone et al., 2022; Riaboff et al., 2022). Essa temática vem ganhando notoriedade, dada sua relevância para o monitoramento nutricional (L. Wang et al., 2023), diagnóstico de distúrbios metabólicos (W. Xu et al., 2019a) e avaliação do bem-estar animal (Gladden et al., 2020b). Sensores vestíveis, como acelerômetros e giroscópios, têm se mostrado promissores nesse contexto, fornecendo dados sobre os padrões de movimentação dos animais, como demonstrado por Pereira et al., (2021). Entretanto, a simples coleta de dados não garante sua utilidade prática. É necessário aplicar modelos capazes de interpretar corretamente esses sinais e traduzi-los em informações úteis ao manejo.

Para tal finalidade, algoritmos de aprendizado de máquina têm sido amplamente empregados. Métodos supervisionados, como Random Forest (RF), Decision Tree (DT), Gradient Boosting (GB), K-Nearest Neighbors (KNN), Support Vector Machine (SVM) e Redes Neurais Artificiais (ANN), destacam-se como ferramentas eficazes para tarefas de classificação de comportamentos com base em dados provenientes de sensores (Riaboff et al., 2022; Simanungkalit et al., 2021; Yu et al., 2021). Apesar disso, a eficácia desses modelos está condicionada a uma série de fatores metodológicos, como o volume, a qualidade e a heterogeneidade dos dados.

Apesar dos avanços, observa-se na literatura uma escassez de estudos que realizem comparações sistemáticas entre diferentes algoritmos em múltiplos contextos zootécnicos. A maioria dos trabalhos existentes utiliza validações do tipo Holdout, onde os dados de treinamento e teste provêm da mesma base (Riaboff et al., 2022). Isso pode inflar artificialmente as métricas de desempenho (Coelho Ribeiro et al., 2021). Poucos autores adotam validações externas (Henrique Silva, 2021), nas quais os modelos são testados em dados provenientes de populações, ambientes ou condições distintas daquelas utilizadas no treinamento. Essa limitação compromete a capacidade de generalização dos modelos, restringindo sua aplicabilidade prática (Gallitto et al., 2025; Wilson et al., 2025).

Além disso, modelos treinados com dados homogêneos, oriundos de um único sistema de produção, raça ou categoria animal, tendem a apresentar desempenho satisfatório apenas naquele cenário específico, falhando quando expostos a variações no ambiente de coleta (Lo et al., 2021). Por isso, é interessante pensar em estratégias que promovam a unificação e diversificação das bases de dados, ampliando a variabilidade presente no treinamento e permitindo que os modelos aprendam padrões mais gerais e robustos.

Pensando nessas limitações, buscou-se avaliar diferença entre os modelos de classificação ao utilizar modelos treinados com dados de diferentes sistemas de produção, ou seja, dados heterogêneos. Para isso, foram conduzidas oito coletas de dados entre 2023 e 2025, contemplando diferentes sistemas de produção (pasto, confinamento, compost barn, free stall e tie stall), categorias e raças de bovinos (leiteiros e de corte), bem como condições ambientais variadas. Também foram utilizados diversos modelos de classificação, como Random Forest, Gradient

Boosting, Redes Neurais Artificiais e K-Nearest Neighbors, buscando observar se há diferença entre os modelos, principalmente ao serem expostos a um banco de dados heterogêneo.

Nossa hipótese é de que um banco de dados heterogêneo irá apresentar melhores métricas de desempenho para a validação externa, tanto para duas classes, (alimentando e não alimentando), quanto para três classes, (alimentando, ruminando e ócio). Em contrapartida, unificar os bancos de dados não apresentará melhores diferenças quando utilizar a validação Holdout. Outra hipótese é que o modelo ANN apresentará métricas abaixo das demais.

Assim, este capítulo apresenta a fundamentação teórica e experimental para o desenvolvimento de um sistema de identificação automática de comportamento animal, com foco na aplicação de metodologias de inteligência artificial em bases de dados heterogêneas e realistas. Os resultados pretendem oferecer subsídios práticos para a aplicação da Zootecnia de Precisão no campo, contribuindo para a adoção de tecnologias mais confiáveis, eficientes e economicamente viáveis no manejo de bovinos.

5.3 Material E Métodos

O experimento foi aprovado pelo Comitê de Ética no Uso de Animais (protocolo nº 012/2023-CEUA).


5.3.1 Instrumentação

Os equipamentos utilizados foram desenvolvidos em colaboração com o Departamento de Automática da Universidade Federal de Lavras, com base em estudos preliminares voltados à identificação dos componentes mais adequados. O dispositivo é composto por um microcontrolador modelo ESP32-WROOM-32U, acoplado a um módulo de gravação de dados em cartão SD, um acelerômetro e giroscópio triaxial MPU-6050, um módulo de relógio de tempo real (RTC) DS3231, uma chave tátil de quatro conexões e um LED indicador de status na cor vermelha, conforme pode ser observado na Figura 11. Modelo semelhante ao proposto por (Schmeling et al., 2021).

Uma placa de circuito impresso (PCB) foi projetada especificamente para este sistema, sendo confeccionada por meio de corrosão química em solução de cloreto cúprico (CuCl_2), a fim de estabelecer a conexão entre os componentes. A alimentação do dispositivo era fornecida por baterias externas com capacidade de 10.000 mAh, garantindo autonomia operacional adequada ao tempo de coleta previsto, levando em consideração o custo energético do sistema. Todo o conjunto eletrônico foi acondicionado em um case produzido por impressão 3D, utilizando filamento de acrilonitrila butadieno estireno (ABS), e fixado em cabrestos ajustáveis para assegurar estabilidade e conforto durante o uso pelos animais.

A frequência de aquisição dos dados foi estabelecida em 1 Hz, correspondente a uma coleta por segundo. Os dados eram armazenados localmente no cartão SD, sendo posteriormente exportados em formato de planilha (.CSV), contendo oito colunas: data, hora, valores dos eixos X, Y e Z do acelerômetro, e valores dos eixos X, Y e Z do giroscópio.

Figura 11: Foto do equipamento utilizado, bem como os componentes presentes



Legenda: 1 - Microcontrolador ESP32-WROOM-32U; 2 - Acelerômetro e giroscópio triaxial MPU-6050; 3 - Módulo cartão SD; 4 - RTC DS3231; 5 - Chave tátil; 6 - Placa de circuito impresso; 7 - LED Vermelho; 8 - Case; 9 - Bateria 10.000mAh.

Todas as técnicas de aprendizado de máquina foram conduzidas utilizando a linguagem de programação Python, versão 3.12.7, por meio do ambiente de desenvolvimento integrado Jupyter Notebook. Para a execução das rotinas analíticas e geração dos resultados, foram empregadas as bibliotecas pandas, numpy, time, threading, sys, sklearn, seaborn e matplotlib.pyplot, amplamente reconhecidas e validadas pela comunidade científica para processamento de dados, visualização gráfica e modelagem estatística. A infraestrutura computacional utilizada consistiu em um sistema equipado com processador Intel® Core™ i3-8100 CPU @ 3.60GHz (quatro núcleos), 32,0 GB de memória RAM (composta por dois módulos Corsair de 16,0 GB cada), e sistema operacional Windows 10 Enterprise 64 bits, Versão 22H2.

5.3.2 Coletas

Foram realizadas oito coletas de dados entre os anos de 2023 e 2025, abrangendo diferentes sistemas de produção, raças, categorias animais e condições de manejo, conforme descrito a seguir:

A primeira coleta, denominada 1_Leite_Pasto, foi conduzida em área experimental pertencente ao Departamento de Zootecnia da Universidade Federal de

Lavras, localizada no município de Ijaci, MG (21°14'04.5"S, 44°58'08.6"W; altitude de 918 metros). Utilizando uma novilha leiteira da raça Holandesa, não gestante e não lactante, mantida em pastagem de *Urochloa brizantha* (Hochst ex A. Rich) Stapf cv. Marandu. A coleta teve duração de 12 horas, das 06h00 às 18h00.

A segunda coleta, 2_Leite_Compost, ocorreu em propriedade comercial no município de Três Corações, MG (21°14'04.5"S, 44°58'08.6"W; 918 m). Foi utilizada uma novilha Holandesa em lactação, mantida em sistema Compost Barn e alimentada com Ração Totalmente Misturada (TMR). A coleta foi realizada por três dias consecutivos, com duração diária de 12 horas (06h00 às 18h00).

A terceira coleta, 3_Leite_TieStall, foi realizada em propriedade comercial no município de Ijaci, MG (mesmas coordenadas geográficas). Duas novilhas Holandesas lactantes, alojadas em sistema Tie Stall e alimentadas com TMR, foram monitoradas durante um único dia, em período de 12 horas (06h00 às 18h00).

A quarta coleta, também denominada 4_Leite_TieStall, ocorreu na mesma propriedade e condições da anterior, porém com quatro novilhas Holandesas lactantes. A coleta foi conduzida em três períodos não consecutivos, cada um com três dias consecutivos, totalizando nove dias de monitoramento contínuo (24 horas por dia).

A quinta coleta, 5_Leite_FreeStall, foi realizada em área experimental da UFLA, em Ijaci, MG (21°14'04.5"S, 44°58'08.6"W; 918 m). Envolveu uma novilha Holandesa lactante mantida em sistema Free Stall, alimentada com Ração Parcialmente Misturada (PMR). Os dados foram coletados durante dois dias consecutivos, por 12 horas diárias (06h00 às 18h00).

A sexta coleta, 6_Leite_FreeStall, também realizada em área experimental da UFLA, envolveu três novilhas Holandesas lactantes sob manejo idêntico ao da quinta coleta (Free Stall + PMR). A coleta foi realizada por três dias consecutivos, com duração de 12 horas diárias.

A sétima coleta, 7_Corte_Pasto, foi conduzida na área experimental da UFLA no município de Lavras, MG (21°14'04.5"S, 44°58'08.6"W; 918 m), com três vacas de corte da raça Tabapuã em companhia de seus bezerros. Os animais foram mantidos

em pastagem de *Urochloa brizantha* cv. *Marandu*. A coleta teve duração de quatro dias consecutivos, com registro de dados das 06h00 às 18h00.

A oitava e última coleta, 8_Corte_Confinado, também ocorreu na área experimental da UFLA, em Lavras, MG. Participaram dois bovinos de corte machos da raça Tabapuã, confinados em baias individuais e alimentados com TMR, sem acesso à pastagem. Os dados foram coletados ao longo de três dias consecutivos, com 12 horas de registro diário (06h00 às 18h00).

5.3.4 Observações Visuais

A mesma metodologia foi adotada para as observações visuais e coleta dos dados durante todos os experimentos. Os equipamentos foram fixados na região da nuca dos animais com o auxílio de cabrestos ajustáveis, garantindo a permanência do dispositivo na mesma posição durante todo o período de coleta. Os equipamentos foram configurados para registrar dados com frequência de 1 Hz, ou seja, uma leitura por segundo. Os cabrestos eram colocados nos animais no início de cada sessão de coleta e removidos ao seu término.

As observações visuais foram realizadas de forma simultânea à coleta automatizada dos dados, conduzidas por uma equipe previamente treinada. As observações ocorreram de forma contínua, com os observadores registrando o horário exato de cada mudança comportamental — hora, minuto e segundo — em planilhas impressas, posteriormente digitalizadas. Cada planilha continha as seguintes informações: identificação do animal, equipamento utilizado, data da coleta, horário da mudança comportamental e o comportamento observado.

A única exceção a essa metodologia ocorreu no banco de dados 4_Leite_TieStall, no qual as observações comportamentais foram realizadas em intervalos fixos de 5 minutos. Para esses registros, foram preservados os dois minutos anteriores e os dois minutos posteriores à marcação, excluindo os dados do minuto exato da observação. Por exemplo, se uma observação foi realizada às 10h10min00s, foram mantidos os registros de 10h08min00s a 10h12min00s, excluindo-se o minuto de 10h10min00s.

Os comportamentos observados foram classificados em três categorias principais, conforme descrito na Tabela 3:

Tabela 3: Descrição dos comportamentos ingestivos observados em bovinos.

Comportamento	Descrição
Alimentação	Refere-se ao momento em que o bovino abaixa a cabeça e se alimenta, seja em área de pastagem ou no cocho. Pequenos deslocamentos enquanto se alimenta também são incluídos nesta categoria.
Ruminação	Ato de ruminar e mastigar o alimento, podendo ocorrer com o animal em pé ou deitado.
Ócio	Estado em que o animal não está se alimentando nem ruminando, incluindo momentos em que está parado em pé ou deitado, em deslocamento de maiores distâncias ou bebendo água.

5.3.5 Aplicação Das Técnicas De Machine Learning

As planilhas contendo os dados oriundos dos equipamentos e das observações visuais foram integradas por meio de scripts desenvolvidos em linguagem Python. A integração ocorreu com base na correspondência entre os horários registrados, e os horários não observados foram preenchidos de acordo com o comportamento identificado nas observações visuais. Em seguida, foi realizado um processo de limpeza de dados, no qual foram removidos os registros com informações ausentes provenientes das observações visuais ou dados incoerentes registrados pelos equipamentos. As variáveis extraídas dos equipamentos foram utilizadas como variáveis preditoras (X) nos modelos de classificação adotados. Já os dados oriundos das observações visuais foram utilizados como variáveis resposta para os modelos (y).

Os oito bancos de dados originais foram unificados em um único, denominado BD_Unificado. Posteriormente, os nove bancos (oito originais mais o BD_Unificado) foram reorganizados em dois grupos distintos de classificação: Alimentação vs

Ruminação vs Ócio e Alimentação vs Não Alimentação, sendo que “Não Alimentação” é a fusão das categorias Ruminação e Ócio (Tabela 4).

Tabela 4: Denominação dos bancos de dados utilizados para duas e três classes.

Alimentação vs Ruminação vs Ócio	Alimentação vs Não Alimentação
1_Leite_Pasto	1_Leite_Pasto
2_Leite_Compost	2_Leite_Compost
3_Leite_TieStall	3_Leite_TieStall
4_Leite_TieStall	4_Leite_TieStall
5_Leite_FreeStall	5_Leite_FreeStall
6_Leite_FreeStall	6_Leite_FreeStall
7_Corte_Pasto	7_Corte_Pasto
8_Corte_confinado	8_Corte_confinado
BD_Unificado	BD_Unificado


Com os bancos de dados devidamente organizados, procedeu-se à aplicação dos modelos de Machine Learning. Para isso, foram selecionados quatro algoritmos amplamente utilizados na literatura científica: Random Forest (RF), um modelo de aprendizado baseado em conjuntos de árvores de decisão, conhecido por sua robustez e boa capacidade de generalização (Breiman, 2001). Light Gradient Boosting Machine (LGBM), um algoritmo de boosting eficiente que utiliza uma abordagem baseada em histogramas para acelerar o processo de treinamento, mantendo elevada precisão (Ke et al., 2017). K-Nearest Neighbors (KNN), um método não paramétrico baseado na similaridade entre instâncias, onde a classificação é realizada pela maioria dos k vizinhos mais próximos (Cover & Hart, 1967) e Artificial Neural Networks (ANN), redes neurais multicamadas capazes de modelar relações complexas entre variáveis, frequentemente empregadas em tarefas de classificação e regressão (Goodfellow, 2016).

5.3.6 Estratégias De Validação

Foram adotadas duas abordagens de validação distintas. Holdout 80:20, onde 80% dos dados foram utilizados para treinamento e 20% para validação. E Validação Externa. Para a validação Holdout 80:20, além dos resultados individuais, a média dos valores obtidos em cada métrica de desempenho será considerado. Já para a validação externa, diferentes combinações de bancos de dados foram utilizadas para o treinamento e validação, onde cada banco de dados individual foi utilizado uma vez


para treinamento e sete vezes para validação. A Figura 12 apresenta as combinações adotadas.

Figura 12: Estratégia de validação, adotando um banco de dados para treinamento e o restante para validação.



Para a validação externa do banco de dados unificado, todos os bancos de dados foram utilizados para validação. Contudo, foram retirados do banco de dados de treinamento aqueles que seriam utilizados na validação, garantindo que o algoritmo não tivesse acesso aos dados originais, conforme Figura 13. Para a aplicação das estratégias de validação externa, apenas o algoritmo com melhores resultados será utilizado.

Figura 13: Estratégia de validação externa, adotando como treinamento a unificação “-K” banco de dados e para treinamento o banco de dados “K”.



5.3.7 Avaliação De Desempenho

As métricas para avaliação do desempenho dos modelos foram realizadas a partir da matriz de confusão (Figura 14), gerada por scripts desenvolvidos em Python. A partir dela, foram calculadas, também por meio de scripts, as seguintes métricas:

$$\text{Acurácia} = \frac{TP+TN}{TP+TN+FP+FN} \quad , \text{mede a proporção de classificações corretas (TP e TN) em relação ao total de predições.}$$

$\text{Precisão} = \frac{TP}{TP+FP}$,que é a capacidade do modelo de predizer com assertividade a classe “Positiva” sobre todas as vezes que um dado era de fato positivo.

$\text{Recall} = \frac{TP}{TP+FN}$,mede a capacidade do modelo de identificar corretamente a classe “Positiva” sobre todas as vezes que ele classificou um dado como positivo.

F1-Score, definida pela equação: $\frac{TP}{TP+\frac{1}{2}(FP+FN)}$,Representa a média harmônica entre precisão e recall, especialmente útil em cenários com desequilíbrio entre as classes.

Figura 14: Esquema ilustrativo de uma matriz de confusão.

		Previsto	
		Positivo	Negativo
Real	Positivo	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Para a predição de duas classes — Alimentação vs Não Alimentação — a classe “Alimentação” é definida como “Positiva”, e a classe “Não Alimentação” é definida como “Negativa”. Assim, temos os acertos do modelo representados por True Positive (TP), quando o dado é corretamente classificado como positivo, e True Negative (TN), quando o dado é corretamente classificado como negativo. Já os erros são representados por False Positive (FP), quando um dado é incorretamente classificado como negativo, sendo na verdade positivo, e False Negative (FN), quando o dado é classificado como positivo, mas pertence à classe negativa.

Para a predição de três classes — Alimentação vs Ruminação vs Ócio — o modelo realiza três predições independentes: na primeira, “Alimentação” é considerada Positiva, enquanto “Ruminação” e “Ócio” são Negativas; na segunda, “Ruminação” é Positiva, e as demais são Negativas; e na terceira, “Ócio” é Positiva, e as demais Negativas. Para cada uma dessas rodadas, uma matriz de confusão e as métricas de desempenho (Acurácia, Precisão, Recall e F1-Score) são calculadas individualmente. A matriz de confusão final é composta pela combinação das três, e as métricas finais são obtidas pela média dos resultados das três classificações.

5.4. Resultado E Discussão

5.4.1 Considerações Gerais

Ao final da coleta dos oito bancos de dados, foi possível reunir aproximadamente dois milhões de registros (Tabela 3), um volume significativamente superior aos dados reportados na literatura, como os de Coelho Ribeiro et al., (2021), que utilizaram 72.328 dados comportamentais de bovinos da raça Tabapuã, Decandia et al., (2018), com 69.975 dados de ovelhas da raça Sarda, e Watanabe et al., (2021), que trabalharam com 101.144 dados comportamentais de bovinos da raça Nelore, todos provenientes de animais mantidos a pasto. É amplamente reconhecido que a quantidade de dados pode impactar diretamente a capacidade de classificação dos modelos classificadores, conforme evidenciado por Althnian et al., (2021), que avaliaram algoritmos de aprendizado de máquina em 20 conjuntos de dados médicos, com tamanhos variando de pequenos (80 a 1.040 dados) a grandes (até 245.057 dados). Os autores observaram uma queda substancial na acurácia, precisão, recall e F1-score à medida que o tamanho dos conjuntos de dados diminuía. De forma similar, Persons et al., (2024) realizaram uma análise do comportamento de bovinos a pasto, constatando uma acurácia média de 98% no banco de dados completo (28.244 registros) e de apenas 58% no banco de dados reduzido (282 registros). Andrew, (2018) complementa que, apesar de uma melhoria contínua na classificação com o aumento da quantidade de dados, existe um limite após o qual o acréscimo de novos dados tem um impacto reduzido na performance do modelo. Nesse ponto, a qualidade dos dados se torna mais determinante do que a quantidade, destacando a importância de um conjunto de dados bem estruturado e representativo para a eficácia dos modelos de aprendizado de máquina.

As categorias de dados apresentam uma distribuição não uniforme, o que é esperado, uma vez que os comportamentos dos animais variam ao longo do dia. Arablouei et al., (2021), por exemplo, relataram uma divisão de 51,96% do tempo dedicado ao pastejo, 39,58% à ruminação e apenas 8,45% ao ócio ao observar bovinos de corte Angus mantidos em sistema a pasto, embora os autores não tenham especificado o período de observação. Em contraste, Chelotti et al., (2023) realizaram duas observações bem definidas de bovinos de leite mantidos a pasto. Na primeira, os animais foram monitorados por intervalos de 4 horas em seis dias não

consecutivos, com os animais gastando 48,4% do tempo em pastejo, 38,6% em ruminação e 13,0% em outras atividades. Já na segunda observação, realizada ao longo de 24 horas em seis dias não consecutivos, os bovinos despenderam 38,3% do tempo no pastejo, 23,7% na ruminação e 38,0% em outras atividades. De maneira similar aos estudos mencionados, observamos também um maior tempo dedicado à atividade de pastejo, com 48,35% no BD 1_Leite_Pasto e 42,57% no BD 7_Corte_Pasto. Essa discrepância em relação aos outros comportamentos pode ser atribuída ao fato de que as observações foram realizadas durante um período de 12 horas, representando apenas uma amostra do comportamento diário dos animais. Portanto, a duração da observação pode influenciar significativamente a proporção de tempo registrada para cada atividade, sugerindo a necessidade de um monitoramento mais extenso para capturar o comportamento total dos animais de forma mais precisa.

Por outro lado, para animais mantidos em sistemas de confinamento, observa-se uma redução no tempo dedicado à alimentação, uma vez que o alimento está sempre disponível. Norring et al., (2012) demonstraram que bovinos da raça Holandesa, mantidos em sistema Tie Stall, passaram 46,7% do tempo em ócio, 37,3% em ruminação e 16,0% se alimentando, resultados próximos aos observados em nosso estudo para esse tipo de sistema de criação. Por sua vez, McWilliams et al., (2022) relataram que vacas da raça Holandesa, mantidas em sistema Free Stall, dedicaram 43,8% do tempo ao ócio, 34,4% à ruminação e 21,8% à alimentação. Esses resultados também se alinham com os dados obtidos em nosso estudo, onde os bancos de dados para animais confinados apresentaram uma média de 36,75% do tempo gasto em ócio, 37,59% em ruminação e 22,92% na alimentação. Esse padrão de comportamento sugere que, independentemente do sistema de confinamento, os bovinos tendem a investir a maior parte do tempo em ócio e ruminação, com uma proporção significativamente menor de tempo dedicado à alimentação, refletindo as condições específicas de manejo e disponibilidade de alimento.

Ao todo, ao unificar todos os bancos de dados obtidos neste estudo, 27,64% dos dados correspondem ao comportamento de alimentação, 34,64% ao comportamento de ruminação e 35,63% ao comportamento de ócio. O sistema de criação que apresentou maior equilíbrio na distribuição dos dados foi o sistema Compost Barn, contudo foi o único com apenas uma amostra, enquanto o sistema que exibiu o maior desequilíbrio foi o 8_Corte_confinado. Neste último, os animais eram

alimentados apenas duas vezes ao dia, sem qualquer intervenção adicional. Esse padrão de alimentação resultava em uma ingestão rápida do alimento, seguida por um período de ruminação e longos períodos de ócio, já que os animais não tinham acesso a uma área de pastagem. Esse manejo específico levou a um desequilíbrio, com uma predominância do comportamento de ócio, refletindo as características de alimentação e o ambiente restritivo do sistema de confinamento. Esse desequilíbrio destaca a importância do manejo adequado, que pode afetar significativamente os padrões comportamentais dos animais e, conseqüentemente, a análise e interpretação dos dados coletados. A quantidade de dados por classe pode ser observada na Tabela 5.

Tabela 5: Quantidade de dados por classe, isso é comportamento, e quantidade total de dados.

	n total	Alimentação	Ruminação	Ócio	Não alimentação
1_Leite_Pasto	28 482	13 771	5 194	9 522	21 951
2_Leite_Compost	78 621	25 761	26 600	26 260	52 860
3_Leite_TieStall	40 134	7 452	14 196	18 487	32 683
4_Leite_TieStall	911 539	207 007	401 147	303 385	704 532
5_Leite_FreeStall	62 643	15 793	18 613	28 237	46 850
6_Leite_FreeStall	257 348	64 137	88 186	105 026	193 212
7_Corte_Pasto	449 444	191 338	114 728	143 383	258 111
8_Corte_confinado	199 295	35 047	33 669	88 065	121 734
BD_Unificado	2 027 506	560 306	702 333	722 365	1 431 933

O equipamento utilizado apresentou poucos problemas na captura de dados, com a grande maioria das falhas sendo atribuídas à queda dos equipamentos durante intervalos curtos de tempo, frequentemente devido a uma má fixação do equipamento ou do cabresto. Dessa forma, o desenvolvimento de um protótipo próprio, alinhado às nossas necessidades específicas, se mostrou uma estratégia vantajosa, especialmente quando comparado ao estudo de Henrique Silva, (2021), que utilizou um equipamento comercial, não destinado a produção animal, que falhou na captura de dados em até 92% dos casos. Como melhorias futuras, destaca-se a implementação de uma nova estratégia para fixação dos equipamentos nos cabrestos, visando minimizar as quedas. Observou-se que alguns animais pressionavam os equipamentos contra cercas ou árvores, o que ocasionava danos nas estruturas de fixação, que foram confeccionadas em plástico ABS utilizando impressoras 3D. Outra melhoria em perspectiva envolve a adoção de redes sem fio para o envio dos dados,

5.4.3 Classificação Binária

No contexto da Zootecnia de Precisão, além das especificações do equipamento utilizado, persiste uma questão crucial sobre qual algoritmo é mais eficaz para identificar o comportamento ingestivo de bovinos. Esse tema foi abordado por diversos autores, como Coelho Ribeiro et al., (2021) e Simanungkalit et al., (2021), que indicaram o modelo RF como superior aos modelos ANN, DT e SVM. Por outro lado, Khanh et al., (2020) argumentam para uma superioridade do modelo GB em relação ao modelo RF. Warner et al., (2020) demonstraram que tanto os modelos RF quanto o GB apresentaram um bom equilíbrio entre sensibilidade e especificidade ao identificar o comportamento de vacas Holandesas oriundos de 229 rebanhos comerciais de leite no Canadá. Assim como outros autores, como Cairo et al., (2020), Muzzo et al., (2025), e Yu et al., (2021), que não observaram diferenças significativas entre os modelos RF, GB e ANN (Tabela 8). Esses resultados sugerem que, embora o RF tenha sido amplamente reconhecido por sua eficácia em diversos estudos, a escolha do modelo ideal pode depender de características específicas dos dados e do contexto experimental. Isso implica que, para além do desempenho geral dos modelos, é necessário considerar fatores como a natureza dos dados, a complexidade do comportamento a ser classificado e a interpretabilidade do modelo ao tomar decisões sobre a aplicação desses algoritmos.

Tabela 8: Acurácias observadas em alguns artigos sobre a classificação do comportamento de bovinos para diferentes modelos classificadores. Random Forest (RF), Decision Tree (DT), Gradient Boosting (GB), Suport Vector Machine (SVM) e Rede Neural Artificial (ANN)

	RF (%)	DT (%)	GB (%)	SVM (%)	ANN (%)
Ribeiro et al. (2021)	76	-	-	-	74
Simanungkalit et al. (2021)	88 - 98	65 - 91		83 - 97	-
Khanh et al. (2020)	84	-	86	80	-
Muzzo et al. (2025)	73	-	74	71	-
Cairo et al. (2020)	67 - 96	-	-	-	67 - 96
Mladenova et al. (2024)	87 - 89	88	-	83	-
Yu et al. (2021)	91	89.8	91	92	90

Embora existam diversos estudos que abordam essa problemática, não foram encontrados artigos que comparem os diferentes modelos classificadores quando aplicados a diferentes sistemas de criação, o que levanta a questão de se os resultados podem ser exclusivamente atribuídos aos modelos ou à forma como foram

aplicados. Nesse contexto, um dos objetivos deste estudo foi avaliar a performance de quatro modelos classificadores na previsão do comportamento ingestivo de bovinos em diferentes sistemas de criação. Para isso, todos os oito bancos de dados, bem como o banco de dados unificado, foram submetidos à classificação das classes utilizando os quatro algoritmos selecionados. Os resultados obtidos de cada modelo, avaliados nos diferentes sistemas de criação, podem ser observados na Tabela 9. Esse enfoque permite não apenas comparar a eficácia dos modelos em termos de precisão e robustez, mas também explorar como os diferentes sistemas de criação podem impactar a performance dos algoritmos, proporcionando uma análise mais holística e contextualizada dos dados.

Tabela 9: Métricas obtidas para cada banco de dados binário, validados pela estratégia Holdout, nos quatro diferentes algoritmos adotados. Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).

	Modelo	Acurácia	Precisão	Recall	F1-Score
1_Leite_Pasto	RF	80.73	62.04	41.36	49.63
	LGB	80.80	62.30	41.44	49.77
	ANN	72.97	30.73	14.14	19.37
	KNN	80.98	63.37	40.60	49.49
2_Leite_Compost	RF	91.01	85.88	87.15	86.51
	LGB	90.98	85.61	87.48	86.53
	ANN	88.34	82.72	81.91	82.32
	KNN	91.12	87.13	85.89	86.50
3_Leite_TieStall	RF	90.15	78.60	68.71	73.32
	LGB	90.03	78.33	68.33	72.99
	ANN	86.28	78.73	41.66	54.59
	KNN	90.03	79.40	66.75	72.53
4_Leite_TieStall	RF	87.81	75.09	69.12	71.98
	LGB	87.63	74.84	68.38	71.47
	ANN	83.84	66.60	57.48	61.70
	KNN	87.67	75.66	67.21	71.19
5_Leite_FreeStall	RF	86.79	74.40	72.10	73.23
	LGB	86.81	74.02	72.96	73.49
	ANN	86.44	69.74	67.01	68.34
	KNN	86.88	74.52	72.39	73.44
6_Leite_FreeStall	RF	83.02	72.95	50.88	59.95
	LGB	82.60	72.01	49.62	58.76
	ANN	76.95	60.71	21.84	32.12
	KNN	82.67	71.99	50.14	59.11
7_Corte_Pasto	RF	87.36	83.81	87.04	85.39
	LGB	87.22	83.77	86.71	85.21
	ANN	84.34	81.96	80.93	81.44
	KNN	87.22	84.38	85.77	85.07
8_Corte_confinado	RF	81.23	66.41	22.16	33.23

	LGB	81.26	69.58	19.69	30.69
	ANN	78.50	48.60	34.77	40.54
	KNN	81.09	62.72	25.37	36.13
BD_Unificado	RF	84.36	73.54	67.73	70.52
	LGB	84.16	73.27	67.16	70.08
	ANN	81.19	71.84	52.49	60.66
	KNN	84.32	74.56	65.63	69.81

Em termos gerais, o algoritmo de ANN apresentou resultados inferiores aos demais na classificação do comportamento ingestivo, especialmente quando considerado o cenário de duas classes e a validação Holdout 80:20. A média de acurácia foi de 86,01% para o modelo RF, 85,92% para o modelo LGB, 85,96% para o modelo KNN e 82,21% para o modelo ANN, com este último apresentando uma diferença de 3,68% em relação aos outros modelos. Esse padrão também se manteve em termos de precisão, onde o modelo ANN obteve um valor 9,98% inferior, com 64,97%, comparado aos 74,90% do RF, 75,06% do LGB e 74,90% do KNN. No que diz respeito ao Recall, o valor obtido para o modelo ANN foi de apenas 49,97%, enquanto para os modelos RF, LGB e KNN, os valores foram de 62,32%, 61,83% e 61,77%, respectivamente. Para o F1-Score, os resultados foram de 66,66% para o RF, 66,11% para o LGB, 66,68% para o KNN e apenas 55,05% para o ANN.

Observa-se que o modelo de ANN foi o que mais exigiu poder computacional e, paradoxalmente, entregou as piores métricas de desempenho, sendo, portanto, considerado ineficiente para a tarefa de classificação do comportamento ingestivo de bovinos. É relevante notar que, no menor banco de dados disponível, o 1_Leite_Pasto, a diferença de desempenho do modelo ANN em comparação aos outros algoritmos foi ainda mais pronunciada. A acurácia apresentou uma diferença de 8,01%, a precisão foi 32,94% inferior, o recall teve uma diferença de 27,30% e o F1-Score apresentou uma disparidade de 30,04%. Esses resultados evidenciam uma limitação significativa na capacidade de classificação do modelo ANN quando a quantidade de dados disponíveis é reduzida, sugerindo que o modelo exige um volume substancial de dados para alcançar uma performance competitiva (Alwosheel et al., 2018; Condon, 2019). O modelo de Redes Neurais Artificiais foi proposto inicialmente por (Mcculloch & Pitts, 1943) com o objetivo de simular redes de neurônios, que poderiam aprender a partir de dados e realizar tarefas de classificação e predição. As ANNs consistem em camadas de neurônios artificiais, onde cada neurônio recebe entradas,

processa essas entradas por meio de uma função de ativação e transmite a saída para a próxima camada.

Os resultados demonstram que, independentemente da quantidade de dados disponíveis, do tipo de coleta ou do sistema de criação, os algoritmos RF, LGB e KNN apresentaram desempenhos similares. Assim, o pesquisador pode optar entre esses algoritmos, selecionando o que melhor se adapta às suas necessidades, seja aquele que demanda menor poder computacional, como o LGB, ou aquele mais amplamente utilizado, como o RF (Riaboff et al., 2022). O modelo RF foi proposto por Breiman, (2001) como uma melhoria do modelo Decision Tree, utilizando uma coleção de árvores de decisão criadas aleatoriamente para realizar tarefas de classificação e regressão. Esse método melhora a acurácia e reduz o risco de *overfitting*, promovendo maior robustez no desempenho do modelo. O LGB, por sua vez, é um modelo desenvolvido pela Microsoft Research (Microsoft, Redmond, Washington, Estados Unidos), com o objetivo de aprimorar o modelo GB, inicialmente proposto por Friedman, (2021). O LGB adota uma técnica de aprendizado supervisionado baseada em otimização iterativa, na qual os modelos classificadores são construídos de forma sequencial, com cada novo modelo corrigindo os erros do anterior. Por fim, o modelo KNN foi proposto por Cover & Hart, (1967) como uma técnica de aprendizado supervisionado, fundamentada na premissa de que itens semelhantes estão localizados próximos uns dos outros no espaço de características. Em conjunto, esses algoritmos fornecem ao pesquisador diversas opções de modelos classificadores, permitindo a escolha com base em fatores como eficiência computacional, popularidade e robustez para a tarefa em questão

Outra questão relevante refere-se à unificação e diversificação dos bancos de dados. Nguyen et al., (2022) propuseram a unificação de três bancos de dados distintos provenientes de repositórios para ampliar a capacidade de classificação do modelo RF. Os autores observaram uma melhoria significativa, com a acurácia aumentando de 82% para os bancos de dados sem unificação para 90% nos dados unificados. De forma semelhante, Hauschild et al., (2022) buscaram diversificar sua base de dados ao utilizar cinco conjuntos de dados biomédicos. A acurácia dos modelos também aumentou substancialmente, saltando de 67% para os dados não unificados para 76% nos dados unificados. Esses estudos sugerem que a unificação e a diversificação dos dados podem ter um impacto positivo na performance dos

modelos classificadores, aumentando sua capacidade de generalização e robustez. No entanto, é importante destacar que, até o momento, não foram encontrados trabalhos que avaliem especificamente os impactos da unificação de diferentes bancos de dados na produção animal, especialmente no contexto de comportamentos de bovinos. Isso representa uma lacuna significativa na literatura, uma vez que a unificação e diversificação de dados pode influenciar a eficácia dos modelos classificadores na área da Zootecnia de Precisão.

Ao comparar a média das métricas dos bancos de dados individuais com o banco de dados unificado (Tabela 10), observa-se uma queda no desempenho dos modelos para Acurácia e Precisão, com exceção do modelo de Redes Neurais Artificiais (ANN). Esse resultado difere das observações na literatura. Contudo, dados relacionados ao comportamento animal são mais complexos e a inter-relação entre animais, plantas e ambientes pode ampliar a complexidade dos modelos. Apesar disso, há uma melhora significativa no Recall e no F1-Score para o banco de dados unificado.

Por exemplo, no caso do modelo RF, a média de desempenho da acurácia para os bancos de dados individuais foi de 86,01% ($\pm 3,92$), enquanto para o banco de dados unificado foi de 84,36%, representando uma queda de 1,65%. A Precisão média dos bancos de dados individuais foi de 74,90% ($\pm 8,06$), superior aos 73,54% observados para o banco de dados unificado, uma diferença de 1,36%. No entanto, o Recall médio dos bancos de dados individuais foi de 62,32% ($\pm 22,66$), enquanto o banco de dados unificado apresentou uma melhoria, com 67,73%. Da mesma forma, o F1-Score foi superior para o banco de dados unificado, com uma média de 70,52%, em comparação aos 66,66% observados para os bancos de dados individuais. Esses resultados indicam que, embora o banco de dados unificado tenha apresentado uma leve redução em algumas métricas, ele também proporcionou uma melhoria considerável em outras, como o Recall e o F1-Score, o que pode indicar que a unificação oferece uma maior consistência e robustez nas predições, proporcionando uma maior estabilidade ao modelo. Consequentemente, permitindo uma classificação mais confiável, especialmente em termos de identificação de verdadeiros positivos.

Tabela 10: Média das métricas observadas nos bancos de dados binário e no banco de dados unificado binário para cada algoritmo adotado e validação Holdout. Random

Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).

	Modelo	Acurácia	Precisão	Recall	F1-Score
Média BDs	RF	86,01	74,90	62,32	66,66
	LGB	85,92	75,06	61,83	66,11
	ANN	82,21	64,97	49,97	55,05
	KNN	85,96	74,90	61,77	66,68
BD_Unificado	RF	84,36	73,54	67,73	70,52
	LGB	84,16	73,27	67,16	70,08
	ANN	81,19	71,84	52,49	60,66
	KNN	84,32	74,56	65,63	69,81

Como já demonstrado, algoritmos treinados com dados heterogêneos, provenientes de diversas fontes, tendem a apresentar melhores resultados do que aqueles treinados com dados homogêneos. Isso ocorre porque o modelo tem acesso a um conjunto mais diversificado de dados, o que possibilita o aprendizado em uma gama mais ampla de cenários. Gong et al., (2019) nos traz um exemplo interessante. Se um algoritmo for treinado apenas com imagens diurnas, ele terá dificuldades em classificar imagens noturnas. Logo, é essencial que o algoritmo tenha acesso a fotos diurnas e noturnas.

Apesar disso, essa melhoria não foi tão pronunciada quando utilizamos a validação Holdout, uma vez que essa estratégia faz uso de dados semelhantes tanto para treinamento quanto para validação, o que tende a inflar as métricas de desempenho (Coelho Ribeiro et al., 2021). A validação Holdout pode não capturar adequadamente as variações que ocorrem em dados heterogêneos, pois ao manter a semelhança entre os dados de treinamento e validação, os modelos podem obter resultados artificialmente mais elevados. Esse comportamento sugere que abordagens de validação mais robustas poderiam oferecer uma avaliação mais fiel do desempenho do modelo, especialmente quando se trabalha com dados provenientes de fontes diversas e com variações significativas.

Pensando nisso, outras estratégias de validação, como Leave-One-Out (Lorand et al., 2025; J. Wang et al., 2022) e validação externa (Henrique Silva, 2021) podem ser mais adequadas. Essas estratégias utilizam dados completamente novos e desconhecidos, exigindo maior capacidade dos algoritmos e, conseqüentemente, resultando em uma queda nas métricas de desempenho (Coelho Ribeiro et al., 2021). Embora essas abordagens forneçam uma avaliação mais rigorosa e realista do

desempenho do modelo, elas tendem a expor as limitações dos algoritmos. Uma possível estratégia para mitigar a queda nas métricas de desempenho ao utilizar validação externa seria realizar o treinamento com dados heterogêneos. Ao integrar dados de diversas fontes e contextos, espera-se que o modelo desenvolva uma maior robustez, sendo mais capaz de lidar com as variações naturais que surgem em ambientes de validação externa. Esses resultados podem ser observados na Tabela 11.

Tabela 11: Métricas obtidas para cada banco de dados binário e banco de dados unificados binário, validados por validação externa, nos quatro diferentes algoritmos adotados.

	Acurácia	Precisão	Recall	F1-Score
<i>Validação Externa 1_Leite_Pasto</i>				
Média dos BDs	74.79	44.19	41.81	39.22
BD Unificado	72.90	44.06	67.17	53.22
<i>Validação Externa 2_Leite_Compost</i>				
Média dos BDs	74.90	67.78	46.78	50.86
BD Unificado	84.72	79.82	71.40	75.38
<i>Validação Externa 3_Leite_TieStall</i>				
Média dos BDs	76.38	38.52	32.12	29.24
BD Unificado	81.72	50.67	59.23	54.62
<i>Validação Externa 4_Leite_TieStall</i>				
Média dos BDs	78.14	55.51	43.19	44.85
BD Unificado	83.57	67.17	54.05	59.90
<i>Validação Externa 5_Leite_FreeStall</i>				
Média dos BDs	75.00	46.90	18.68	26.10
BD Unificado	79.67	75.77	28.47	41.39
<i>Validação Externa 6_Leite_FreeStall</i>				
Média dos BDs	69.61	41.41	38.35	35.96
BD Unificado	72.27	44.79	48.39	46.52
<i>Validação Externa 7_Corte_Pasto</i>				
Média dos BDs	70.47	79.16	41.24	52.04
BD Unificado	78.41	84.04	60.87	70.59
<i>Validação Externa 8_Corte_confinado</i>				
Média dos BDs	73.78	37.48	34.42	34.23
BD Unificado	79.33	84.96	62.52	72.03

Ao analisarmos todas as validações externas, observamos que a unificação dos bancos de dados resultou em uma performance amplamente superior, quando comparada à média dos bancos de dados individuais, em termos de acurácia, precisão, recall e F1-score. Esses resultados corroboram os achados de Nguyen et

al., (2022) e Hauschild et al., (2022), que também identificaram melhorias significativas com a unificação de dados. De forma geral, a acurácia aumentou em 5,92% ($\pm 2,32$), exceto na validação utilizando o banco de dados 1_Leite_Pasto, onde a acurácia diminuiu de 74,79% na média dos bancos individuais para 72,90% na validação externa. Em relação à precisão, o aumento foi de 17,21% ($\pm 15,70$). O recall registrou um aumento expressivo de 19,44% ($\pm 8,03$), indo de uma média de 37,07% para 56,51%. Por fim, o F1-Score, que integra precisão e sensibilidade em uma única métrica, apresentou um aumento impressionante de 20,14% ($\pm 8,78$).

Esses resultados indicam que, de fato, a diversificação da base de dados para o treinamento contribuiu significativamente para a melhoria da eficácia do algoritmo adotado. Acreditamos que essa melhoria tenha ocorrido principalmente devido ao grande desbalanceamento entre as classes, com uma quantidade substancialmente maior de dados referentes à classe "Não Alimentando" em comparação à classe "Alimentando". Essa hipótese é corroborada pela considerável melhoria no F1-Score, uma métrica altamente sensível a desbalanceamentos nos dados, como observado por Tantithamthavorn et al., (2018). Assim, a diversificação do banco de dados emerge como uma estratégia crucial para realizar previsões mais precisas sobre o comportamento animal, permitindo uma maior robustez e generalização dos modelos de classificação.

5.4.4 Classificação Multiclasse

As classificações realizadas com três classes, como "Alimentando", "Ruminando" e "Ócio", representam um desafio adicional para os algoritmos. Ladds et al., (2016) relataram uma situação semelhante ao observar o comportamento de leões-marinhos. Ao analisar a acurácia para duas classes, "Ativo" e "Inativo", os autores observaram uma acurácia média de 85%. No entanto, para a classificação multiclasse, com 4 classes, a acurácia variou entre 60% e 70%, dependendo do modelo classificador adotado. (Mauny et al., 2025) também relatou uma melhora no desempenho dos modelos ao agrupar quatro classes comportamentais de caprinos em apenas classificações binárias, e Hasan et al., (2016), ao tentar classificar entrevistas clínicas de pacientes, onde os modelos perderam precisão à medida que mais categorias foram adicionadas aos algoritmos.

Isso ocorre porque, ao realizar a classificação com apenas duas classes, o modelo faz uma única classificação, entre o negativo (0) e o positivo (1). No entanto,

ao realizar a classificação com três classes, o modelo precisa realizar três classificações distintas. Na primeira, a classe “Alimentação” é definida como positiva, enquanto as classes “Ruminação” e “Ócio” são unificadas e definidas como negativas. Em seguida, a classe “Ruminação” é definida como positiva, e as classes “Alimentação” e “Ócio” são consideradas negativas. Por fim, a classe “Ócio” é definida como positiva, e as classes “Alimentação” e “Ruminação” são definidas como negativas (Andrew, 2018). Para cada classe adicional, uma nova classificação é necessária.

Ao observarmos a Tabela 12, é evidente uma queda nas métricas ao compararmos a classificação com três classes com a de duas classes (Tabela X), ainda que os resultados permaneçam satisfatórios. A acurácia média foi de 70,88% para três classes, em comparação com 84,85% para duas classes. Além disso, o modelo classificador de ANN apresentou os resultados mais insatisfatórios em ambas as abordagens, com a acurácia de 60,43% ($\pm 8,58\%$) para três classes, significativamente abaixo dos 75,64% ($\pm 6,00\%$) para RF, 75,35% ($\pm 6,14\%$) para LGB e 75,00% ($\pm 9,86\%$) para KNN. Embora a adição de categorias multiclasse traga uma maior complexidade para o modelo, o desempenho continua razoavelmente bom, especialmente para modelos como RF, LGB e KNN. A maior dificuldade encontrada no modelo ANN sugere que ele pode ter limitações na capacidade de lidar com problemas multiclasse, especialmente em cenários com um número maior de categorias a serem previstas.

Tabela 12: Métricas obtidas para cada banco de dados multiclasse, validados pela estratégia Holdout, nos quatro diferentes algoritmos adotados, sendo eles Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).

	Modelo	Acurácia	Precisão	Recall	F1-Score
1_Leite_Pasto	RF	78,54	78,55	76,21	77,06
	LGB	78,61	78,30	76,46	77,19
	ANN	71,92	74,68	67,82	69,02
	KNN	77,75	77,38	75,74	76,48
2_Leite_Compost	RF	80,8	80,7	80,9	80,7
	LGB	80,4	80,3	80,4	80,3
	ANN	64,0	64,3	64,2	59,8
	KNN	79,8	79,8	79,9	79,8
3_Leite_TieStall	RF	82,4	81,1	80,9	81,0
	LGB	82,3	81,0	80,8	80,9
	ANN	44,7	14,9	33,3	20,6
	KNN	81,6	80,5	79,6	80,0

4_Leite_TieStall	RF	74,2	73,6	73,4	73,3
	LGB	73,7	73,1	73,0	72,9
	ANN	58,2	59,5	54,0	54,4
	KNN	73,9	73,3	73,2	73,2
5_Leite_FreeStall	RF	78,67	78,17	79,07	78,52
	LGB	78,28	77,82	78,63	78,11
	ANN	69,27	69,91	69,34	69,33
	KNN	78,20	78,07	78,01	77,95
6_Leite_FreeStall	RF	68,54	68,05	67,60	67,79
	LGB	67,74	67,29	66,84	69,03
	ANN	55,01	59,23	50,84	50,67
	KNN	67,96	67,76	66,59	67,02
7_Corte_Pasto	RF	77,10	75,91	75,58	75,56
	LGB	77,08	75,87	75,53	75,54
	ANN	61,03	41,04	54,00	46,29
	KNN	76,54	75,49	74,80	75,08
8_Corte_confinado	RF	64,84	64,61	52,25	54,70
	LGB	64,72	63,89	52,51	54,90
	ANN	59,30	38,90	41,60	37,99
	KNN	64,27	62,55	52,67	54,93
BD_Unificado	RF	70,13	70,13	70,53	70,26
	LGB	69,40	69,44	69,81	69,58
	ANN	50,68	37,25	51,97	41,74
	KNN	70,04	70,25	70,23	70,23

Essa dificuldade é observada também nas demais métricas. A precisão média do algoritmo ANN foi de 52,81% ($\pm 19,85\%$), muito inferior aos 75,09% ($\pm 5,99\%$) para o modelo RF e 74,70% ($\pm 6,20\%$) para o LGB, respectivamente. O modelo KNN obteve uma média de 74,36% ($\pm 6,27\%$) de precisão. Métricas semelhantes foram observadas no Recall, com 73,24% ($\pm 9,55\%$) e 73,02% ($\pm 9,44\%$) para RF e LGB, 72,56% ($\pm 9,56\%$) para KNN e 54,39% ($\pm 12,66\%$) para ANN. No F1-Score, os valores foram de 73,58% ($\pm 8,75\%$) para RF, 73,61% ($\pm 8,50\%$) para LGB, 73,06% ($\pm 8,44\%$) para KNN e 51,01% ($\pm 16,32\%$) para ANN. Reforçando a dificuldade do modelo ANN em lidar com classificações multiclasse.

Diferentemente do que ocorreu para a classificação com duas classes, onde a unificação dos dados resultou em uma queda na acurácia, mas uma melhoria nas demais métricas, na classificação com três comportamentos, a unificação dos bancos de dados causou uma queda em todas as métricas (Tabela 13). Como exemplo, podemos observar o modelo RF. A média de desempenho da Acurácia para os bancos de dados individuais foi de 75,64% ($\pm 6,11$), enquanto para o banco de dados unificado foi de 70,13%, representando uma queda de 5,51%. A precisão média dos bancos

individuais foi de 75,09% ($\pm 5,99$), superior aos 70,13% observados para o banco de dados unificado, uma diferença de 4,36%. O recall médio dos bancos individuais foi de 73,24% ($\pm 9,55$), sendo superior aos 70,53% observados para o banco de dados unificado. Da mesma forma, o F1-Score foi superior para os bancos de dados individuais, com uma média de 73,58% ($\pm 8,75$), em comparação com 70,26% para o banco de dados unificado. Esses resultados podem indicar que a unificação dos bancos de dados torna o processo ainda mais complexo, especialmente porque a complexidade já é ampliada ao predizer três classes em comparação com duas (Andrew, 2018).

Tabela 13: Média das métricas observadas nos bancos de dados multiclasse e no banco de dados unificado multiclasse para cada algoritmo adotado e validação Holdout.

	Modelo	Acurácia	Precisão	Recall	F1-Score
Média BDs	RF	75,64	75,09	73,24	73,58
	LGB	75,35	74,70	73,02	73,61
	ANN	60,43	52,81	54,39	51,01
	KNN	75,00	74,36	72,56	73,06
BD_Unificado	RF	70,13	70,13	70,53	70,26
	LGB	69,40	69,44	69,81	69,58
	ANN	50,68	37,25	51,97	41,74
	KNN	70,04	70,25	70,23	70,23

Legenda: Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).

Apesar da queda nas métricas observada nas classificações multiclasse, para as validações externas (Tabela 14), a unificação do banco de dados ampliou a capacidade de classificação dos modelos, assim como ocorreu para a classificação com dois comportamentos. A acurácia aumentou de 47,32% ($\pm 4,29$) nos bancos de dados individuais para 52,88% ($\pm 5,19$) quando os dados foram unificados. A precisão também apresentou um aumento, passando de 50,32% ($\pm 3,59$) para 55,99% ($\pm 6,70$). O recall registrou uma melhoria considerável, de 47,32% ($\pm 4,29$) para 54,01% ($\pm 5,45$), enquanto o F1-Score aumentou de 45,06% ($\pm 5,71$) para 53,72% ($\pm 6,00$). Esses resultados reforçam a ideia apresentada para duas classes que, ao unificar os dados, houve um aumento na capacidade de classificação dos modelos, provavelmente devido à maior diversidade e volume de dados disponíveis para o treinamento. Mesmo

com a complexidade adicional trazida pela unificação e pela classificação multiclasse, a diversificação e a quantidade de dados podem resultar em um modelo mais robusto e com maior capacidade de generalização, especialmente quando testado em dados externos.

Tabela 14: Métricas obtidas para cada banco de dados multiclasse e banco de dados unificados multiclasse, validados por validação externa, nos quatro diferentes algoritmos adotados.

	Acurácia	Precisão	Recall	F1-Score
Validação Externa 1_Leite_Pasto				
Média dos BDs	47.03	49.43	47.03	41.69
BD_Unificado	53.80	56.87	53.80	54.60
Validação Externa 2_Leite_Compost				
Média dos BDs	41.79	43.42	41.79	41.01
BD_Unificado	44.90	42.83	44.90	43.72
Validação Externa 3_Leite_TieStall				
Média dos BDs	46.99	51.10	46.99	46.01
BD_Unificado	49.87	50.77	49.87	47.11
Validação Externa 4_Leite_TieStall				
Média dos BDs	51.11	52.81	51.11	50.95
BD_Unificado	56.22	58.94	56.22	56.14
Validação Externa 5_Leite_FreeStall				
Média dos BDs	42.09	49.89	42.09	39.74
BD_Unificado	59.70	63.56	59.70	60.04
Validação Externa 6_Leite_FreeStall				
Média dos BDs	52.34	54.08	52.34	51.58
BD_Unificado	50.02	60.57	59.02	58.80
Validação Externa 7_Corte_Pasto				
Média dos BDs	52.34	54.08	52.34	51.58
BD_Unificado	59.02	60.57	59.02	58.80
Validação Externa 8_Corte_confinado				
Média dos BDs	44.86	47.76	44.86	37.90
BD_Unificado	49.54	53.83	49.54	50.51

Legenda: Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN) e K-Nearest Neighbors (KNN).

5.5. Conclusão

Podemos afirmar que, embora a classificação multiclasse imponha um desafio adicional aos algoritmos de aprendizado de máquina, os modelos Random Forest, Light Gradient Boosting e K-Nearest Neighbors mantiveram desempenho satisfatório, tanto em cenários multiclasse quanto em cenários binários. Em contrapartida, as Redes Neurais Artificiais apresentaram desempenho inferior em praticamente todos os cenários, sendo especialmente sensíveis à redução da quantidade de dados e à maior complexidade associada à classificação de três comportamentos.

Também observamos que a utilização de um banco de dados heterogêneo contribui significativamente para a melhoria da capacidade de classificação dos modelos de classificação do comportamento ingestivo de bovinos, especialmente quando avaliados por meio de validações externas. A unificação dos dados oriundos de diferentes sistemas de produção, raças e categorias animais permitiu o treinamento de modelos mais robustos, capazes de generalizar melhor frente à variabilidade dos cenários reais, superando, em grande parte, os desempenhos obtidos com bancos individuais. Isso foi particularmente evidente nas métricas de recall e F1-score, que são fundamentais em contextos de dados desbalanceados, como os encontrados neste estudo.

Portanto, conclui-se que a adoção de dados heterogêneos e a escolha criteriosa do algoritmo, bem como da busca de hiperparâmetros e estratégias de validação, são estratégias essenciais para o avanço da Zootecnia de Precisão, com implicações diretas na acurácia e confiabilidade dos sistemas de monitoramento automatizado do comportamento animal

6. OTIMIZAÇÃO DE MODELOS CLASSIFICADORES PARA A ZOOTECNIA DE PRECISÃO: HIPERPARÂMETROS, BALANCEAMENTO E OBSERVAÇÕES VISUAIS.

6.1 Resumo

A busca por modelos robustos para detecção do comportamento de bovinos ainda necessita de bases metodológicas. Pensando nisso, este capítulo avaliou o impacto de estratégias de hiperparametrização, balanceamento, fixação de sensores, observações visuais e coleta de dados por diferentes intervalos de tempo. Para isso, sensores vestíveis com acelerômetro e giroscópio triaxial foram utilizados para registrar dados em oito diferentes sistemas de produção. Quatro algoritmos foram aplicados: Random Forest (RF), Light Gradient Boosting (LGB), Rede Neural Artificial (ANN), K-Nearest Neighbors (KNN). A busca por hiperparâmetros foi conduzida com Random Search, Busca Bayesiana e Algoritmos Evolutivos. Técnicas de balanceamento incluíram SMOTE, ADASYN, NearMiss e Undersampling aleatório. Também foi comparado o desempenho de sensores fixados na nuca e no colar dos animais. As métricas de desempenho foram acurácia, precisão, sensibilidade e F1-score. A otimização dos hiperparâmetros gerou melhorias significativas na acurácia, sendo a busca bayesiana a mais eficiente em termos de desempenho e tempo. O balanceamento das classes influenciou diretamente os resultados, com destaque para SMOTE e ADASYN, que elevaram o F1-score principalmente em bases desbalanceadas. Sensores na nuca mostraram melhor desempenho na identificação do comportamento de alimentação, sugerindo melhor captura dos movimentos cefálicos. A coleta de dados com intervalos de até 60s manteve métricas satisfatórias. Observações visuais por intervalos de 2 minutos mostraram resultados próximos às contínuas, sendo uma alternativa viável para rotulagem. A integração dessas variáveis aumentou a robustez e aplicabilidade dos modelos preditivos em contextos reais de produção animal. Conclui-se que a escolha criteriosa de estratégias metodológicas impacta significativamente a performance dos modelos e sua viabilidade prática na pecuária de precisão.

6.2 Introdução

Nas últimas décadas, a produção animal tem experimentado transformações profundas, impulsionadas pela convergência de inovações tecnológicas e pela crescente demanda por sistemas de produção mais eficientes e sustentáveis. No âmbito agropecuário, tal movimento culminou na emergência do conceito de "Pecuária 4.0" ou "Zootecnia de Precisão" (Precision Livestock Farming), uma abordagem interdisciplinar que incorpora o uso de sensores, algoritmos, plataformas de integração de dados e sistemas de apoio à decisão.

De acordo com Berckmans, (2014), a Zootecnia de Precisão é descrita como "uma abordagem de monitoramento e gestão em tempo real dos animais de produção, com o objetivo de melhorar a qualidade de vida dos animais, permitindo a detecção precoce de problemas para que medidas corretivas possam ser adotadas de forma imediata. Utiliza tecnologias digitais para o monitoramento contínuo da saúde, do bem-estar e do desempenho dos animais, bem como para avaliar o impacto ambiental da produção animal." Nesse sentido, a Zootecnia de Precisão pode ser caracterizada como um sistema de monitoramento em tempo real, automação de processos e tomada de decisões fundamentada em dados, com o intuito de aprimorar a produtividade, o bem-estar animal e a sustentabilidade ambiental.

Entre as diversas aplicações práticas da Zootecnia de Precisão, destaca-se a identificação automatizada de comportamentos animais, especialmente aqueles relacionados à ingestão de alimentos, como o pastejo, a ruminação e os períodos de ócio (Morrone et al., 2022; Riaboff et al., 2022). Essa área tem ganhado crescente relevância, não apenas pelo seu papel no monitoramento nutricional L. Wang et al., (2023), mas também no diagnóstico de distúrbios metabólicos (W. Xu et al., 2019b) e na avaliação do bem-estar animal (Gladden et al., 2020a). Sensores vestíveis, como acelerômetros e giroscópios, têm se mostrado promissores nesse contexto, fornecendo dados cruciais sobre os padrões de movimentação dos animais, conforme evidenciado por Pereira et al., (2021). No entanto, a mera coleta de dados não assegura sua aplicabilidade prática. Torna-se essencial a implementação de modelos capazes de interpretar de forma precisa esses sinais, traduzindo-os em informações valiosas para o manejo e a gestão dos rebanhos.

Apesar dos avanços recentes, diversas questões permanecem pouco discutidas, o que dificulta a formulação de metodologias eficazes para a aplicação da Zootecnia de Precisão na classificação do comportamento animal. Um dos principais desafios, senão o mais relevante, é a definição dos melhores hiperparâmetros. Estes parâmetros funcionam como "regras" ou "atributos" que controlam a aplicação dos modelos classificadores, sendo cruciais para garantir a eficácia do modelo. A escolha adequada dos hiperparâmetros é essencial para evitar problemas como overfitting e underfitting, que comprometem a generalização e a precisão do modelo. Diversos estudos destacam a necessidade de uma busca sistemática por hiperparâmetros, como observam Ayer, Erdem e Erdal (2024), Hidayaturrohman & Hanada, (2025), e Probst & Bischl, (2019). No entanto, tais artigos são predominantemente voltados à área da saúde ou a testes em bancos de dados públicos, o que limita a aplicabilidade direta desses métodos ao contexto da Zootecnia de Precisão. Nossa hipótese é que abordagens mais robustas, como a Busca Bayesiana, podem se mostrar mais eficientes em comparação a estratégias mais simples, como a Random Search.

Outro ponto crítico refere-se ao impacto do desbalanceamento de classes, uma característica comum nos bancos de dados comportamentais de animais. O desbalanceamento tende a gerar modelos enviesados, uma vez que a predominância de exemplos de uma classe durante o treinamento pode comprometer a qualidade do modelo, favorecendo a classe majoritária. Uma solução comum para esse problema é a aplicação de técnicas de balanceamento, que podem ser divididas em duas abordagens principais: oversampling e undersampling. O oversampling consiste na geração de novos dados a partir da classe minoritária, com o objetivo de equilibrar a quantidade de amostras entre as classes. Por outro lado, o undersampling envolve a remoção de dados da classe majoritária, equilibrando as classes por meio da eliminação de exemplos. Cada uma dessas estratégias apresenta vantagens e limitações, como discutido por Fernández et al., (2018), Y. Yang et al., (2024), e J. Jiang et al., (2025). Para o banco de dados em questão, acreditamos que a aplicação de técnicas de balanceamento pode não ser necessária, uma vez que, apesar do desbalanceamento observado, ainda há uma quantidade suficientemente representativa de exemplos de cada classe ou comportamento, o que é adequado para a realização de uma classificação eficaz.

Adicionalmente, é importante considerar aspectos práticos relacionados à instrumentação, como o local de fixação dos sensores vestíveis. Estes podem ser posicionados em diferentes partes do corpo do animal, como a nuca, o pescoço e as patas. Esta questão se torna particularmente complexa, uma vez que não podemos avaliar apenas a capacidade de classificação dos sensores vestíveis. Também é essencial levar em conta as especificidades da produção animal, incluindo condições ambientais adversas, a resistência dos equipamentos e a viabilidade de implementação pelos produtores rurais (Sharma et al., 2021; Simanungkalit et al., 2021). Nossa hipótese é que os sensores vestíveis fixados na nuca são mais eficazes do que aqueles posicionados no pescoço, pois os equipamentos localizados na nuca amplificam o movimento da cabeça dos animais, o que pode melhorar a capacidade de monitoramento, especialmente durante a busca por alimento.

Outro aspecto fundamental diz respeito às estratégias de observação visual. A coleta de dados pode ser realizada de duas maneiras distintas. A primeira envolve observações contínuas, nas quais se registra o momento exato de transição entre os comportamentos dos animais. Embora essa estratégia ofereça maior precisão nas observações, ela limita o número de animais que podem ser monitorados simultaneamente. Em contrapartida, as observações por intervalos de tempo não proporcionam a mesma precisão quanto ao momento exato da troca de comportamentos, mas permitem a observação de um número maior de animais (Chen et al., 2016; Manfrè et al., 2024; Mitlöhner et al., 2001). Caso optemos por observações em intervalos de tempo, será necessário também determinar o intervalo adequado entre as observações e definir quais dados serão considerados ou descartados. Decandia et al., (2018), por exemplo, argumentam que intervalos de 60 a 120 segundos ainda podem ser utilizados sem comprometer a precisão na classificação dos comportamentos animais. Com base na maior precisão das observações contínuas, nossa hipótese é que as métricas de desempenho associadas a esse tipo de observação serão superiores às obtidas com a observação por intervalos de tempo. Além disso, intervalos de tempo menores seriam mais vantajosos do que intervalos mais longos, uma vez que possibilitam a coleta de uma maior quantidade de dados.

Nossas hipóteses são de que: I) Não haverá diferença entre as diferentes estratégias de busca de hiperparâmetros. II) Estratégias de Undersampling serão superiores a não utilização de estratégias de balanceamento. III) O local mais

adequado para a fixação dos sensores é a nuca. IV) Observações contínuas e por intervalo de 5 minutos apresentarão resultados semelhantes. V) Intervalos de dados de até 2 minutos apresentarão resultados satisfatórios. VI) Observações contínuas serão superiores a intervalos fixos de 2, 5 ou 10 minutos.

Dessa forma, este capítulo tem como objetivo apresentar e comparar diferentes estratégias metodológicas para o desenvolvimento de um sistema automatizado de identificação de comportamentos animais, com ênfase na aplicação de metodologias de inteligência artificial em bancos de dados diversos. Os resultados obtidos contribuirão para a aplicação prática da Zootecnia de Precisão no campo, fornecendo informações valiosas para a adoção de tecnologias mais confiáveis, eficientes e economicamente viáveis no manejo de bovinos.

6.3 material e métodos

O experimento foi aprovado pelo Comitê de Ética no Uso de Animais (protocolo nº 012/2023-CEUA).

6.3.1 Instrumentação


Os equipamentos utilizados foram desenvolvidos em colaboração com o Departamento de Automática da Universidade Federal de Lavras, com base em estudos preliminares focados na identificação dos componentes mais adequados para as necessidades específicas do experimento. O dispositivo é composto por um microcontrolador ESP32-WROOM-32U, integrado a um módulo de gravação de dados em cartão SD, um acelerômetro e giroscópio triaxial MPU-6050, um módulo de relógio de tempo real (RTC) DS3231, uma chave tátil com quatro conexões e um LED indicador de status de cor vermelha, conforme ilustrado na Figura 15. Este modelo segue a linha de desenvolvimento apresentada por Schmeling et al., (2021), com adaptações específicas para atender aos requisitos do presente estudo.

Uma placa de circuito impresso (PCB) foi projetada especificamente para este sistema, sendo fabricada por meio de um processo de corrosão química utilizando uma solução de cloreto cúprico (CuCl_2), com o objetivo de estabelecer as conexões entre os diversos componentes eletrônicos. A alimentação do dispositivo era fornecida por baterias externas com capacidade de 10.000 mAh, garantindo uma autonomia operacional suficiente para o tempo de coleta previsto, levando em consideração as exigências energéticas do sistema. Todo o conjunto eletrônico foi encapsulado em um case produzido por impressão 3D, utilizando filamento de acrilonitrila butadieno estireno (ABS), e fixado em cabrestos ajustáveis, garantindo que o equipamento sempre fosse alojado na nuca dos animais.

A frequência de aquisição dos dados foi configurada para 1 Hz, o que implica na coleta de um conjunto de dados a cada segundo. Esses dados eram armazenados localmente no cartão SD, sendo posteriormente exportados em formato de planilha (.CSV), contendo oito colunas: data, hora, valores dos eixos X, Y e Z do acelerômetro, bem como dos eixos X, Y e Z do giroscópio. Esse método de armazenamento e

estruturação dos dados permitiu um acompanhamento detalhado e preciso dos parâmetros coletados ao longo do experimento.

Figura 15: Foto do equipamento utilizado, bem como os componentes presentes.



1 - Microcontrolador ESP32-WROOM-32U; 2 - Acelerômetro e giroscópio triaxial MPU-6050; 3 - Módulo cartão SD; 4 - RTC DS3231; 5 - Chave tátil; 6 - Placa de circuito impresso; 7 - LED Vermelho; 8 - Case; 9 - Bateria 10.000mAh.

Foram realizadas oito coletas de dados entre os anos de 2023 e 2025, abrangendo diferentes sistemas de produção, raças, categorias animais e condições de manejo, conforme detalhado a seguir:

A primeira coleta, designada 1_Leite_Pasto, foi conduzida em área experimental do Departamento de Zootecnia da Universidade Federal de Lavras, localizada no município de Ijaci, MG (21°14'04.5"S, 44°58'08.6"W, a 918 metros de altitude). Nessa coleta, foi utilizada uma novilha leiteira da raça Holandesa, não gestante e não lactante, mantida em pastagem de *Urochloa brizantha* (Hochst ex A. Rich) Stapf cv. Marandu. A coleta teve duração de 12 horas, das 06h00 às 18h00.

A segunda coleta, 2_Leite_Compost, ocorreu em uma propriedade comercial no município de Três Corações, MG (mesmas coordenadas geográficas e altitude). Nessa coleta, foi utilizada uma novilha Holandesa em lactação, mantida em sistema Compost Barn e alimentada com Ração Totalmente Misturada (TMR). A coleta foi

realizada por três dias consecutivos, com duração diária de 12 horas (06h00 às 18h00).

A terceira coleta, 3_Leite_TieStall_Nuca, foi realizada em propriedade comercial no município de Ijaci, MG, com as mesmas coordenadas geográficas da coleta anterior. Duas novilhas Holandesas lactantes, alojadas no sistema Tie Stall e alimentadas com TMR, foram monitoradas durante um único dia, com duração de 12 horas (06h00 às 18h00).

Uma coleta adicional foi conduzida simultaneamente à terceira coleta, utilizando os mesmos animais descritos anteriormente, que foram equipados com sensores vestíveis fixados por meio de colares no pescoço. Esse banco de dados foi denominado 3.5_Leite_TieStall_Pescoço, e as coletas ocorreram durante o mesmo intervalo de tempo e sob as mesmas condições do sistema experimental.

A quarta coleta, também denominada 4_Leite_TieStall, ocorreu na mesma propriedade e sob as mesmas condições da coleta anterior, porém com quatro novilhas Holandesas lactantes. Esta coleta foi conduzida em três períodos não consecutivos, cada um com três dias consecutivos, totalizando nove dias de monitoramento contínuo (24 horas por dia).

A quinta coleta, 5_Leite_FreeStall, foi realizada em área experimental da UFLA, em Ijaci, MG, com uma novilha Holandesa lactante mantida em sistema Free Stall e alimentada com Ração Parcialmente Misturada (PMR). Os dados foram coletados durante dois dias consecutivos, por 12 horas diárias (06h00 às 18h00).

A sexta coleta, 6_Leite_FreeStall, também realizada em área experimental da UFLA, envolveu três novilhas Holandesas lactantes sob manejo idêntico ao da quinta coleta (Free Stall + PMR), com coleta realizada por três dias consecutivos, com duração de 12 horas diárias.

A sétima coleta, 7_Corte_Pasto, foi conduzida na área experimental da UFLA no município de Lavras, MG, com três vacas de corte da raça Tabapuã, acompanhadas por seus bezerros. Os animais foram mantidos em pastagem de *Urochloa brizantha* cv. Marandu. A coleta teve duração de quatro dias consecutivos, com registro de dados das 06h00 às 18h00.

A oitava e última coleta, 8_Corte_Confinado, também ocorreu na área experimental da UFLA, em Lavras, MG. Participaram dessa coleta dois bovinos de corte machos da raça Tabapuã, confinados em baias individuais e alimentados com TMR, sem acesso à pastagem. Os dados foram coletados ao longo de três dias consecutivos, com 12 horas de registro diário (06h00 às 18h00).

6.3.2 Observações Visuais

A mesma metodologia foi adotada para as observações visuais e coleta de dados durante todos os experimentos. Os equipamentos foram fixados na região da nuca dos animais com o auxílio de cabrestos ajustáveis, assegurando que o dispositivo permanecesse na mesma posição ao longo de todo o período de coleta. No banco de dados 3.5_Leite_TieStall_Pescoço os equipamentos foram fixados no pescoço dos animais, como colares. Os equipamentos foram configurados para registrar dados com frequência de 1 Hz, ou seja, uma leitura a cada segundo. Os cabrestos eram colocados nos animais no início de cada sessão de coleta e removidos ao término da mesma.

As observações visuais ocorreram simultaneamente à coleta automatizada de dados, sendo conduzidas por uma equipe previamente treinada. Essas observações foram realizadas de forma contínua, com os observadores registrando o horário exato de cada mudança comportamental — hora, minuto e segundo — em planilhas impressas, que posteriormente foram digitalizadas. Cada planilha continha as seguintes informações: identificação do animal, equipamento utilizado, data da coleta, horário da mudança comportamental e o comportamento observado.

A única exceção a essa metodologia ocorreu no banco de dados 4_Leite_TieStall, onde as observações comportamentais foram realizadas em intervalos fixos de 5 minutos. Para esses registros, os dois minutos anteriores e os dois minutos posteriores à marcação da observação foram preservados, excluindo-se os dados do minuto exato da observação. Por exemplo, se uma observação foi realizada às 10h10min00s, os registros de 10h08min00s a 10h12min00s foram mantidos, excluindo-se o minuto de 10h10min00s.

Os comportamentos observados foram classificados em duas categorias principais, conforme descrito na Tabela 15:

Tabela 15: Descrição dos comportamentos ingestivos observados em bovinos.

Comportamento	Descrição
Alimentação	Refere-se ao momento em que o bovino abaixa a cabeça e se alimenta, seja em área de pastagem ou no cocho. Pequenos deslocamentos enquanto se alimenta também são incluídos nesta categoria.
Não Alimentação	Estado em que o animal não está se alimentando, incluindo momentos em que está parado em pé ou deitado, ruminando, em deslocamento de maiores distâncias ou bebendo água.

6.3.3 Aplicação Das Técnicas De Machine Learning

As planilhas contendo os dados oriundos dos equipamentos e das observações visuais foram integradas por meio de scripts desenvolvidos na linguagem Python. A integração ocorreu com base na correspondência entre os horários registrados nos dois tipos de dados. Os horários não observados foram preenchidos com o comportamento identificado nas observações visuais. Posteriormente, foi realizado um processo de limpeza de dados, no qual foram removidos os registros com informações ausentes provenientes das observações visuais ou dados incoerentes registrados pelos equipamentos. As variáveis extraídas dos equipamentos foram utilizadas como variáveis preditoras (X) nos modelos de classificação, enquanto os dados oriundos das observações visuais foram utilizados como variáveis resposta (y). Os bancos de dados originais foram unificados em um único banco de dados, denominado BD_Unificado.

Com os bancos de dados devidamente organizados, procedeu-se à aplicação dos modelos de Machine Learning para responder às questões levantadas. Para essa análise, foi selecionado o algoritmo Random Forest (RF), amplamente utilizado em pesquisas sobre a classificação do comportamento animal (Riaboff et al., 2022). Como estratégia de validação, foi adotada a técnica Holdout, também documentada por Coelho Ribeiro et al., (2021) e Henrique Silva, (2021).

6.3.4 Busca Por Hiperparâmetro

Para identificar a melhor estratégia de busca por hiperparâmetros, foram aplicados três algoritmos específicos para essa finalidade: Random Search, Busca Bayesiana e Algoritmos Evolutivos. Os limites de busca foram mantidos consistentes para todas as estratégias, conforme detalhado na Tabela 16, com exceção dos Algoritmos Evolutivos, que adotam uma abordagem distinta. Para esse caso, foram selecionadas cinco gerações para o algoritmo evolutivo (`generations=5`), com uma população de soluções de tamanho 20 (`population_size=20`), fixação do estado randômico em 42 (`random_state=42`), nível de verbosidade 2 (`verbosity=2`) e utilização de todos os núcleos de processamento disponíveis (`n_jobs=-1`).

Tabela 16: Limites para a busca por hiperparametros para as estratégias de Random Search e Busca Bayesiana.

Parâmetros	Limites			
n estimators	10	200	10	
Max depth	None	2	20	2
Min samples split	2	11	2	
Min samples leaf	1	11	2	
Bootstrap	True	False		

6.3.5 Balanceamento Dos Dados


Para avaliar o impacto do balanceamento dos dados, foram aplicadas e comparadas quatro técnicas distintas, contrapondo-as a um cenário com dados não balanceados. Todas as abordagens utilizaram a técnica de busca pelos melhores hiperparâmetros por meio da Otimização Bayesiana. Dentre essas, duas estratégias são classificadas como Oversampling: *Synthetic Minority Oversampling Technique* (SMOTE) de Chawla et al., (2002) e o *Adaptive Synthetic Sampling* (ADASYN) de He et al., (2008) que buscam gerar novos dados a partir dos dados já existentes. As outras duas estratégias adotadas visam balancear os dados por meio da remoção de exemplos da classe majoritária, um processo denominado Undersampling. As técnicas utilizadas nesse contexto foram o *NearMiss* (Zhang & Mani, 2023) e o *Random Undersampling*.

6.3.6 Local De Fixação

Para determinar o local ideal de fixação dos sensores vestíveis, foram utilizados exclusivamente os bancos de dados 3_Leite_TieStall_Nuca e

3.5_Leite_TieStall_Pescoço, os quais foram coletados simultaneamente e sob as mesmas condições experimentais, com a única variável modificada sendo o local de fixação do equipamento, conforme ilustrado na Figura 16. Para essa análise, a classe "Não Alimentando" será subdividida em duas classes distintas: "Ruminação" e "Ócio". A classe "Ruminação" refere-se ao ato de ruminar dos animais, independentemente de estarem em pé ou deitados, enquanto a classe "Ócio" inclui todos os comportamentos dos animais que não sejam "Alimentação" ou "Ruminação". Dessa forma, os bancos de dados foram analisados em duas configurações: binária (duas classes) e multiclasse (três classes). A busca pelos melhores hiperparâmetros foi realizada utilizando a estratégia de Otimização Bayesiana. Além disso, os bancos de dados não foram submetidos a nenhum tipo de tratamento de balanceamento, garantindo que a análise se concentre exclusivamente na comparação entre os locais de fixação dos sensores vestíveis, sem a interferência de modificações nas distribuições das classes.

Figura 16: Esquema do local de fixação dos equipamentos vestíveis.



6.3.7 Intervalo De Captura De Dados

Para investigar como o intervalo de captura de dados podem influenciar as predições, o primeiro passo constituiu em verificar se as observações visuais feitas em intervalos de tempo específicos foram semelhantes às observações visuais contínuas. Para isso, as observações visuais foram agrupadas, e, em seguida, foi realizada uma simulação de uma observação visual contínua com duração de 5

minutos. Durante essa simulação, foi calculada a porcentagem do tempo dedicado às atividades de "Alimentação" e "Não Alimentação", sendo a última subdividida em "Ruminação" e "Ócio".

Com base nessa simulação, foram adotadas estratégias específicas para a aplicação do algoritmo de predição, que foram comparadas com as predições obtidas a partir de observações contínuas. A primeira estratégia consistiu na seleção de intervalos de tempo próximos às observações a cada 5 minutos. Foram analisados três tipos de intervalos: o primeiro, em que as observações visuais de 5 minutos ocorreram com intervalo fixo de 5 minutos; o segundo, em que foram consideradas observações visuais de 5 minutos com intervalo de 1 minuto anterior e posterior à coleta, totalizando um intervalo de 2 minutos; e o terceiro, em que foram consideradas observações visuais de 5 minutos com intervalo de 1 minuto posterior à coleta. Por exemplo, se um comportamento de "Alimentação" foi registrado às 10:15 da manhã, no primeiro caso, o intervalo de 10:10 até 10:15 foi considerado como "Alimentação". No segundo caso, o intervalo de 10:14 a 10:16 foi classificado como "Alimentação", e no terceiro caso, apenas o horário de 10:15 foi classificado como "Alimentação".

Outra estratégia foi a aplicação do algoritmo de predição diretamente nos dados exatos das observações. Nesse caso, foram utilizados apenas os valores registrados no momento preciso da observação. As observações ocorreram a cada 2 minutos, 5 minutos e 10 minutos. Por exemplo, para o comportamento "Alimentação" registrado às 10:15 da manhã, apenas o dado coletado às 10:15:00 foi utilizado para classificar o comportamento do animal.

Por fim, também foram realizadas análises considerando diferentes intervalos de captura de dados. Os intervalos de captura utilizados foram: 1 segundo (1 Hz), 2 segundos (2 Hz), 5 segundos (5 Hz), 10 segundos (10 Hz), 30 segundos (30 Hz) e 60 segundos (60 Hz). Esses intervalos permitirá uma avaliação detalhada de como a frequência de coleta de dados influencia o desempenho do modelo de predição, conforme explorado por (Decandia et al., 2018).

6.3.8 Estratégia De Validação E Métricas De Desempenho

Foi adotada a estratégia de validação Holdout 80:20, onde 80% dos dados foram utilizados para treinamento e 20% para validação.

As métricas para avaliação do desempenho dos modelos foram realizadas a partir da matriz de confusão (Figura 17), gerada por scripts desenvolvidos em Python. A partir dela, foram calculadas, também por meio de scripts, as seguintes métricas:

Acurácia = $\frac{TP+TN}{TP+TN+FP+FN}$, mede a proporção de classificações corretas (TP e TN) em relação ao total de predições.

Precisão = $\frac{TP}{TP+FP}$, que é a capacidade do modelo de prever com assertividade a classe “Positiva” sobre todas as vezes que um dado era de fato positivo.

Recall = $\frac{TP}{TP+FN}$, mede a capacidade do modelo de identificar corretamente a classe “Positiva” sobre todas as vezes que ele classificou um dado como positivo.

F1-Score, definida pela equação: $\frac{TP}{TP+\frac{1}{2}(FP+FN)}$, representa a média harmônica entre precisão e recall, especialmente útil em cenários com desequilíbrio entre as classes.

Tempo de Processamento, definido como o tempo gasto pelo algoritmo para processar todos os cálculos realizados para a aplicação completa dos algoritmos de classificação.

Figura 17: Esquema ilustrativo de uma matriz de confusão

		Previsto	
		Positivo	Negativo
Real	Positivo	Verdadeiro Positivo (TP)	Falso Negativo (FN)
	Negativo	Falso Positivo (FP)	Verdadeiro Negativo (TN)

Para a predição de duas classes — Alimentação vs Não Alimentação — a classe “Alimentação” é definida como “Positiva”, e a classe “Não Alimentação” é definida como “Negativa”. Assim, temos os acertos do modelo representados por True Positive (TP), quando o dado é corretamente classificado como positivo, e True Negative (TN), quando o dado é corretamente classificado como negativo. Já os erros são representados por False Positive (FP), quando um dado é incorretamente

classificado como negativo, sendo na verdade positivo, e False Negative (FN), quando o dado é classificado como positivo, mas pertence à classe negativa.

6.4 Resultado E Discussão

6.4.1 Considerações Gerais

Ao final da coleta dos bancos de dados, foram reunidos aproximadamente dois milhões de registros (Tabela 3), um volume consideravelmente superior ao encontrado em estudos anteriores, como os de Coelho Ribeiro et al., (2021), que utilizaram 72.328 dados comportamentais de bovinos da raça Tabapuã, Decandia et al., (2018), com 69.975 dados de ovelhas da raça Sarda, e Watanabe et al., (2021), que trabalharam com 101.144 dados comportamentais de bovinos da raça Nelore, todos provenientes de animais mantidos a pasto.

A literatura científica aponta que a quantidade de dados pode influenciar diretamente a capacidade de classificação dos modelos. Por exemplo, Althnian et al., (2021) avaliaram algoritmos de aprendizado de máquina em 20 conjuntos de dados médicos, com tamanhos variando de pequenos (80 a 1.040 dados) a grandes (até 245.057 dados), observando uma queda significativa na acurácia, precisão, recall e F1-score conforme o tamanho dos conjuntos de dados diminuía. De maneira semelhante, Persons et al., (2024) analisaram o comportamento de bovinos a pasto e encontraram uma acurácia média de 98% no banco de dados completo (28.244 registros), que caiu para apenas 58% no banco de dados reduzido (282 registros). Andrew, (2018) complementa que, embora a classificação melhore com o aumento da quantidade de dados, existe um limite após o qual a adição de novos dados tem um impacto reduzido no desempenho do modelo. Nesse estágio, a qualidade dos dados se torna mais determinante do que a quantidade, sublinhando a importância de um conjunto de dados bem estruturado e representativo para a eficácia dos modelos de aprendizado de máquina. Como podemos observar na Tabela 17.

Tabela 17: Quantidade de dados observados para cada Banco de Dados obtido. Considerando quantidade total e quantidade por classe.

	n total	Alimentação	Ruminação	Ócio
1_Leite_Pasto	28 482	13 771	5 194	9 522
2_Leite_Compost	78 621	25 761	26 600	26 260
3_Leite_TieStall	40 134	7 452	14 196	18 487
3.5_Leite_TieStall_Pescoço	45 262	9744	17110	18408
4_Leite_TieStall	911 539	207 007	401 147	303 385
5_Leite_FreeStall	62 643	15 793	18 613	28 237
6_Leite_FreeStall	257 348	64 137	88 186	105 026

7_Corte_Pasto	449 444	191 338	114 728	143 383
8_Corte_confinado	199 295	35 047	33 669	88 065
BD_Unificado	2 027 506	560 306	702 333	722 365

O equipamento utilizado apresentou poucos problemas na captura de dados, sendo que a maioria das falhas ocorreu devido à queda dos dispositivos durante intervalos curtos de tempo, frequentemente em razão de uma fixação inadequada do equipamento ou do cabresto. Nesse contexto, o desenvolvimento de um protótipo personalizado, adaptado às nossas necessidades específicas, se revelou uma estratégia vantajosa, especialmente quando comparado ao estudo de Henrique Silva, (2021), que utilizou um equipamento comercial, não destinado à produção animal, e que falhou na captura de dados em até 92% dos casos. Como melhorias futuras, destaca-se a implementação de uma nova estratégia para fixação dos equipamentos nos cabrestos, com o objetivo de minimizar as quedas. Foi observado que alguns animais pressionavam os equipamentos contra cercas ou árvores, resultando em danos nas estruturas de fixação, que foram confeccionadas em plástico ABS com o uso de impressoras 3D. Outra melhoria em perspectiva envolve a adoção de redes sem fio para o envio dos dados, eliminando a necessidade de substituição dos equipamentos ao final de cada intervalo de coleta. Essa inovação permitiria uma coleta de dados contínua, além de reduzir custos operacionais e aprimorar a eficiência do sistema como um todo.

6.4.2 Melhores Hiperparâmetros

Probst & Bischl, (2019) demonstraram que a busca por hiperparâmetros pode resultar em melhorias substanciais no desempenho dos modelos. Os autores avaliaram oito modelos distintos para a classificação de classes em 38 bancos de dados, observando uma melhoria no desempenho de todos os modelos testados, com destaque para o algoritmo de Gradiente Boosting (GB). A melhoria foi moderada para o modelo K-Nearest Neighbors (KNN) e de magnitude baixa, mas ainda perceptível, para o modelo Random Forest (RF). Em nosso estudo, a busca pelos melhores hiperparâmetros foi conduzida por meio de três estratégias: Random Search, busca Bayesiana e algoritmos evolutivos. Os melhores hiperparâmetros encontrados para cada uma dessas estratégias estão detalhados na Tabela 18.

Tabela 18: Melhores hiperparâmetros obtidos para cada estratégia de busca por hiperparâmetros.

	Random Search	Bayesiana	Alg. evolutivos
n estimators	140	197	100
Min samples split	2	8	
Min samples leaf	9	9	
Max depth	None	20	3
Bootstrap	False	False	
Time (minutos)	492.16	391	115.60
Acurácia (%)	84.36	84.24	83.34

É interessante observar que, embora não tenha sido observado um valor semelhante para os hiperparâmetros nas estratégias de Random Search e Busca Bayesiana, a acurácia entre os modelos foi bastante próxima. A principal diferença entre essas duas abordagens foi o tempo de processamento, com a Random Search apresentando um tempo de execução 101 minutos mais longo do que a busca Bayesiana, o que corrobora os achados de Hidayaturrohman & Hanada, (2025). Por outro lado, a busca por Algoritmos Evolutivos foi a mais rápida, com um tempo de apenas 115,60 segundos, mas obteve os menores valores de acurácia, precisão, recall e F1-Score (Tabela 19). Apesar disso, os valores ainda são consistentes, sugerindo que essa estratégia pode ser vantajosa quando se busca uma maior agilidade no processamento dos dados. Vale destacar que, em um banco de dados de maior escala, o tempo de processamento e a demanda computacional podem se tornar fatores ainda mais decisivos na escolha da estratégia mais adequada.

Tabela 19: Parâmetros de desempenho para o modelo treinado com cada um dos melhores hiperparâmetros selecionados.

	Random	Bayesiana	Alg. evolutivos
Acurácia (%)	84.36	84.24	83.34
Precisão (%)	73.54	73.56	72.22
Recall (%)	67.73	67.06	64.51
F1-Score (%)	90.70	90.80	90.53

Hidayaturrohman & Hanada, (2025) avaliaram o desempenho e a eficiência computacional de diferentes métodos de otimização de hiperparâmetros, incluindo Grid Search, Random Search e Bayesian Search, na predição de readmissão e mortalidade de pacientes com insuficiência cardíaca, utilizando dados clínicos. Os modelos classificadores adotados foram Random Forest (RF), Gradient Boosting (GB)

e Support Vector Machine (SVM). Em termos de acurácia, não foi observada diferença significativa entre os métodos para nenhum dos modelos classificadores. Esses resultados são consistentes com os encontrados em nosso estudo, no qual não houve diferença substancial entre os métodos Random Search e Bayesian Search em relação à acurácia dos modelos testados.

Liashchynskyi & Liashchynskyi, (2019) compararam três métodos populares de otimização de hiperparâmetros. Sendo eles o Grid Search, Random Search e Algoritmo Genético, um tipo de Algoritmo Evolutivo, em redes neurais convolucionais (CNNs), utilizando o dataset CIFAR-10. Diferentemente dos resultados relatados por Hidayaturrohman et al. (2025), os autores observaram uma acurácia superior para Random Search e Algoritmos Genéticos, com valores de 85,8% para Random Search, 85,7% para Algoritmos Genéticos e 83% para Grid Search. Esses resultados contrastam com os observados em nosso estudo, no qual o Algoritmo Evolutivo obteve desempenho inferior. Quanto ao tempo de processamento, os métodos Grid Search e Algoritmos Genéticos foram mais demorados, levando cerca de 4 horas, enquanto o método Random Search exigiu 2,7 horas.

Por fim, Ayer, Erdem e Erdal (2024) propuseram uma estratégia de busca de hiperparâmetros denominada Estratégia Evolutiva Híbrida (HES), outro tipo de Algoritmo Evolutivo, para classificar 12 conjuntos de dados públicos. Os autores encontraram uma acurácia média de 84,12% para Grid Search, 85,21% para Random Search e 87,45% para HES, evidenciando que o método baseado em Algoritmos Evolutivos obteve valores significativamente superior.

Esses resultados reforçam a ideia de que não há um consenso definitivo sobre qual estratégia de busca de hiperparâmetros é a mais eficaz, conforme ilustrado na Tabela 20. Tudo depende da disponibilidade computacional e de tempo.

Tabela 20: Acurácia observada em diferentes artigos que comparam estratégias de busca por hiperparametros.

Referência	Random Search	Bayesiana	Alg. Evolutivos	Grid Search
Presente estudo	84,36 %	84,24 %	83,34 %	-
Hidayaturrohman, Q. A., & Hanada, E. (2025)	61,39 %	61,78 %	-	61,39 %
Liashchynskyi, P. & Liashchynskyi, P. (2019)	85,80 %	-	85,70 %	83,00 %
Ayer, Erdem e Erdal (2024)	85,21 %	-	87,45 %	84,12 %

6.4.3 Balanceamento De Dados

Para avaliar o impacto do balanceamento dos dados, foram aplicadas e comparadas quatro técnicas distintas, contrastando-as com um cenário de dados não balanceados. Todas as abordagens utilizaram a técnica de busca pelos melhores hiperparâmetros por meio da Otimização Bayesiana. Dentre essas, duas estratégias são classificadas como “*Oversampling*”, ou seja, técnicas que geram novos dados a partir da classe minoritária, com o objetivo de equilibrar a quantidade de amostras entre as classes (Hussain et al., 2022; Shelke et al., 2017). As técnicas de *Oversampling* utilizadas foram a *Synthetic Minority Oversampling Technique* (SMOTE) e o *Adaptive Synthetic Sampling* (ADASYN).

O SMOTE é um método que cria novas instâncias de dados da classe minoritária, gerando exemplos sintéticos por meio da interpolação entre instâncias existentes nessa classe. A principal vantagem dessa abordagem é sua capacidade de evitar a duplicação dos exemplos, o que favorece a generalização do modelo (Fernández et al., 2018; C. Yang et al., 2024). Em contraste, o ADASYN é uma variação do SMOTE que foca na geração de exemplos sintéticos para as instâncias minoritárias mais difíceis de classificar, com base na sua distribuição de densidade. Essa técnica visa aumentar a quantidade de amostras nas regiões mais desbalanceadas do espaço de características, o que resulta em um aprendizado mais robusto para as classes minoritárias (He et al., 2008; J. Jiang et al., 2025).

As outras duas estratégias aplicadas visam balancear os dados por meio da remoção de dados da classe majoritária, um processo denominado *Undersampling*. As técnicas utilizadas nesse contexto foram o NearMiss e a busca randômica. O NearMiss é uma técnica que seleciona as instâncias da classe majoritária mais próximas das instâncias da classe minoritária, com o objetivo de reduzir o número de exemplos da classe majoritária sem perder representatividade das instâncias mais relevantes Nayan et al., (2023). Em contraste, a busca randômica, ou Random Undersampling, realiza a seleção aleatória de dados a serem eliminados da classe majoritária, visando equilibrar a distribuição entre as classes Yang et al., (2024). As métricas de desempenho para as quatro estratégias de balanceamento mencionadas, bem como para o cenário sem balanceamento, podem ser observadas na Tabela 21.

Tabela 21: Métricas de desempenho observadas para as diferentes estratégias de balanceamento de dados e sem balanceamento.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
Desbalanceado	84.36	73.54	67.73	70.52
Oversampling				
SMOTE	83.35	79.04	80.88	79.84
ADASYN	81.13	77.14	81.62	78.42
Undersampling				
NearMiss	65.64	67.69	71.95	64.48
Random	81.96	77.76	81.63	79.05


A primeira observação relevante é que a estratégia NearMiss se mostrou amplamente inferior em comparação com as demais estratégias e ao banco de dados desbalanceado. Essa técnica visa otimizar a remoção de dados, eliminando as instâncias mais próximas da fronteira que separa as classes, com o objetivo de aumentar a distância entre as classes. No entanto, essa remoção teve um impacto negativo significativo no desempenho de nosso modelo.

Esse resultado está em consonância com os achados de Nayan et al., (2023), que também observaram uma redução na acurácia ao aplicar a técnica NearMiss em um sistema para o diagnóstico de diabetes. Os autores relataram uma acurácia média de 93,7% para o banco de dados desbalanceado, 93,4% para o banco de dados balanceado com SMOTE, e apenas 87,8% para o banco de dados com a técnica NearMiss. Embora não tenham fornecido uma explicação clara para a queda de desempenho, os autores sugeriram que a perda de informações e a complexidade das classes poderiam ser fatores determinantes. De maneira semelhante, Tahfim & Chen, (2024) observaram resultados similares ao aplicar a estratégia *NearMiss* em comparação com as técnicas SMOTE e ADASYN para prever a gravidade de lesões em um conjunto de dados desbalanceado sobre acidentes com caminhões de grande porte, sem, contudo, explicitar as razões para a queda no desempenho.

Acreditamos que a queda no desempenho observada em nosso estudo ocorreu devido ao fato de a classe "Não alimentando" ser originada pela junção dos comportamentos "Ócio" e "Ruminação". É possível que um desses comportamentos tenha dados numericamente próximos à classe "Alimentação", de modo que esses dados foram eliminados, impactando negativamente a predição do modelo. Barwick et al., (2018) já demonstrou que algumas classes podem ser mais próximas entre si,

como no estudo com ovelhas mantidas a pasto, no qual os autores observaram que os comportamentos de "Ócio" e "Pastejo" eram mais próximos entre si do que o comportamento de "Locomoção", conforme ilustrado na imagem 18.

Figura 18: Representação gráfica de dados referentes a locomoção (Walking), Ócio (Standing) e pastejo (Grazing).



Legenda: Adaptado de Barwick (2017)

As estratégias SMOTE, Random Undersampling e ADASYN apresentaram acurácias semelhantes entre si, mas inferiores à do banco de dados desbalanceado, o que contrasta com o que é comumente relatado na literatura. Wongvorachan et al., (2023), por exemplo, observaram acurácias superiores para técnicas de *oversampling*, com 87,7% para Random Oversampling e 77,9% para SMOTE, em comparação com 73,36% para um banco de dados desbalanceado e 70,5% para Random Undersampling, quando aplicadas a um banco de dados com desbalanceamento moderado. Para um banco de dados com desbalanceamento extremo, as acurácias foram de 98,4% para Random Oversampling, 90,5% para SMOTE, 88,87% para o banco desbalanceado e 73,1% para Random Undersampling.

Apesar dessa igualdade nas acurácias, as estratégias SMOTE, Random Undersampling e ADASYN apresentaram resultados superiores para as métricas de Precisão, Recall e F1-Score em comparação com os dados desbalanceados. Isso

sugere que, embora tenha ocorrido uma queda na acurácia, os modelos tratados com essas técnicas foram mais consistentes, demonstrando maior eficiência na classificação da classe "Não alimentação". Portanto, essas estratégias podem ser vantajosas quando se busca maior consistência e equilíbrio nas classificações das classes como um todo, especialmente em cenários nos quais a precisão na classificação da classe minoritária é crucial.

6.4.4 Local De Fixação Dos Sensores Vestíveis

O local de fixação dos sensores vestíveis apresenta uma ampla divergência na literatura. Alguns autores fixam os sensores na nuca dos animais, como (Coelho Ribeiro et al., 2021) e Arablouei et al., (2021), enquanto outros optam por fixá-los no pescoço, como Dissanayake et al., (2024) e Mladenova et al., (2024). Existem também aqueles que fixam os sensores vestíveis nas patas dos animais (Pereira et al., (2021) ou nas orelhas Simanungkalit et al., (2021). Outros autores ainda fixam esses equipamentos na calda dos animais, com o objetivo de identificar a atividade de defecação (Williams & Zhan Lai, (2022). Diante dessa diversidade de abordagens, buscamos comparar as métricas de desempenho para bancos de dados binários e multiclasse a fim de identificar se o local de fixação dos sensores vestíveis influencia a classificação das classes. Os resultados dessa comparação estão detalhados na Tabela 22.

Tabela 22: Métricas de desempenho para equipamentos vestidos na nuca e no colar de bovinos para dois grupos de dados, Binário e Multiclasse.

	Acurácia (%)	Precisão (%)	Recall (%)	F1-Score (%)
Binário				
Colar	87.85	87.34	87.85	87.13
Nuca	90.18	89.80	90.18	89.97
Multiclasse				
Colar	73.47	73.66	73.47	72.68
Nuca	80.83	79.91	80.83	79.62

Equipamentos fixados nas patas apresentam o desafio de precisarem ser extremamente resistentes, pois estarão expostos a condições adversas, como lama e poeira. Por outro lado, sensores vestíveis fixados nas orelhas, como brincos, devem ser leves para evitar causar desconforto nos animais. Nossos equipamentos não foram projetados para a fixação nesses locais. Nesse contexto, (Simanungkalit et al.,

2021) demonstraram que sensores vestíveis fixados em colares apresentam desempenho superior em comparação aos sensores fixados em brincos. Os autores relataram uma acurácia de 92,4% para os sensores vestíveis no colar, contra 87,5% para os brincos. Da mesma forma, a precisão foi de 92,9% para identificar o comportamento de deitar usando colares, em contraste com 87,5% para a classificação do comportamento de deitar com brincos.

Tanto para o banco de dados binário quanto para o multiclasse, o equipamento fixado na nuca apresentou desempenho superior ao fixado na coleira. A diferença foi ainda mais pronunciada no banco de dados multiclasse, que é mais complexo, onde a acurácia diminuiu em 7,36%. No entanto, apesar dessa diferença de desempenho, os sensores vestíveis fixados em colares são mais simples de vestir e ajustar, enquanto os cabrestos exigem ajustes específicos para cada animal, principalmente durante o seu crescimento. Portanto, a praticidade também deve ser considerada no desenvolvimento de tecnologias, pois, como argumentado por Sharma et al., (2021), N. Wang et al., (2006) e Bewley et al., (2015), é fundamental que a tecnologia seja fácil de implementar e operar pelos produtores rurais, garantindo também um treinamento adequado para o uso eficaz.

6.4.5 Observações Visuais

Usualmente, alguns autores realizam observações contínuas do comportamento animal, como evidenciado por Fuentes et al., (2023) e Ledoux et al., (2023). Outros, como Marumo et al., (2024), adotam a abordagem de observações por intervalos de tempo. De fato, ao realizar observações contínuas, obtemos uma certeza total sobre a porcentagem de tempo dedicada a cada atividade, o que é particularmente útil para detectar mudanças rápidas de comportamento ou comportamentos de curta duração. Por outro lado, observações por intervalos de tempo simplificam o processo de coleta de dados, permitindo que um único observador acompanhe vários animais simultaneamente (Manfrè et al., 2024; Mitlöhner et al., 2001).

Nossos resultados indicam que observações realizadas em intervalos de tempo podem substituir eficientemente as observações contínuas, como mostrado na Tabela 23. Esses achados, no entanto, contrariam os resultados de Manfrè et al., (2024), que

relataram desempenho superior para observações contínuas, especialmente quando realizadas em intervalos menores, como 30 segundos. De acordo com esses autores, intervalos mais curtos foram particularmente eficazes na classificação de comportamentos de curta duração, como vocalizações e exploração, além de comportamentos mais longos, como "Alimentação".

Tabela 23: Tem despendido, em porcentagem, para cada comportamento quando expostos a observações contínuas e observações a cada 5 minutos.

	Observação Contínua	Observação a cada 5 minutos
Alimentação (%)	28.23	28.41
Não Alimentação (%)	71.77	71.58
Ruminação (%)	35.38	35.48
Ócio (%)	36.39	36.10

Uma abordagem interessante é proposta por Chen et al., (2016), que comparam a contagem de ocorrência de um comportamento e o tempo total dedicado a cada atividade. Esses autores sugerem que, para medir a duração total de um comportamento, amostragens por intervalos de tempo são suficientes. No entanto, para quantificar a frequência de ocorrência de um comportamento, apenas a observação contínua é considerada confiável. Assim, a adoção da observação contínua ou por intervalo de tempo depende única e exclusivamente do objetivo do estudo.

Isso sugere que, ao considerar a classificação do comportamento animal por meio de sensores e algoritmos, é viável adotar intervalos fixos de tempo para a observação. No entanto, ao adotar essa abordagem, estamos sacrificando a precisão no momento exato da transição entre comportamentos, o que pode comprometer a acurácia na identificação de mudanças comportamentais. Nesse contexto, cabe ao pesquisador refletir sobre a precisão necessária para a coleta dos dados, levando em consideração a aplicação da inteligência artificial, o tamanho do banco de dados e a disponibilidade de pessoal qualificado para realizar as observações visuais do comportamento animal. Essa reflexão é crucial para balancear a praticidade da coleta de dados com a necessidade de informações precisas para a análise comportamental.

6.4.6 Intervalos De Dados

Inicialmente, foi buscado manter a base de dados utilizando intervalos de tempo, definindo observações visuais a cada 5 minutos. A partir disso, foram considerados três cenários distintos. No primeiro cenário, todos os dados incluídos nos 5 minutos seguintes ao intervalo de observação foram considerados como o comportamento descrito (5 minutos). No segundo cenário, os dados contidos no intervalo de um minuto anterior e um minuto posterior à observação foram considerados como o comportamento descrito (2 minutos). Por fim, no terceiro cenário, apenas os dados contidos no minuto posterior à observação foram mantidos e considerados como o comportamento observado (1 minuto). Conforme figura 19.

Figura 19: Esquema ilustrativo da aplicação dos intervalos de dados ao longo do tempo.

	Observação					
	10:04	10:05	10:06	10:07	10:08	10:09
5 minutos		✓	✓	✓	✓	✓
2 minutos	✓	✓				
1 minuto		✓				

Por exemplo, se o comportamento "Alimentando" for registrado às 10:05, no primeiro cenário, chamado 5 minutos, todos os dados entre 10:05:00 e 10:09:59 estariam classificados como "Alimentando". No segundo cenário, denominado 2 minutos, os dados entre 10:04:00 e 10:05:59 seriam considerados como "Alimentando". Finalmente, no terceiro cenário, ou 1 minuto, apenas os dados do minuto de 10:05:00 até 10:05:59 estariam classificados como "Alimentando". Os resultados dessas análises estão detalhados na Tabela 24

Tabela 24: Quantidade total de dados e métricas de desempenho para bancos de dados com observações contínuas versus intervalos de coleta de dados.

	Contínuo	1 minuto	2 minutos	5 minutos
n dados	2027514	405430	810797	2027514
Acurácia (%)	84.36	83.98	83.72	82.49
Precisão (%)	73.54	73.06	72.82	70.53
Recall (%)	67.73	66.45	65.33	62.91
F1-Score (%)	70.52	69.60	68.87	66.51

Todos os intervalos apresentaram valores de Acurácia, Precisão, Recall e F1-Score inferiores aos observados para as observações contínuas. Contudo, a queda foi mínima, especialmente entre os dados contínuos e o intervalo de 1 minuto. Para o intervalo de 5 minutos, a queda foi mais acentuada, mas, ainda assim, os valores obtidos foram satisfatórios.

Essa diferença pode ser atribuída ao fato de que, com observações visuais, não sabemos o momento exato da troca de comportamento dos animais. Dessa forma, uma parte dos dados inevitavelmente será classificada de maneira incorreta. Quando selecionamos intervalos mais curtos, como 1 minuto, diminuimos a probabilidade de selecionar dados errôneos, uma vez que a quantidade de dados utilizados é menor. Por exemplo, entre os intervalos de 5 minutos, temos 300 dados, enquanto no intervalo de 2 minutos temos 120 dados e, no intervalo de 1 minuto, 60 dados.

Além disso, é possível que a mudança de comportamento aconteça nos primeiros segundos após a observação de um comportamento. Nesse caso, uma grande quantidade de dados será classificada de forma incorreta. Por exemplo, se o comportamento de um bovino for classificado como "Alimentação" às 10:05:00, mas mudar para "Não Alimentação" às 10:05:30, ao utilizarmos um intervalo de 1 minuto, teremos 30 dados classificados corretamente e 30 incorretamente. Se utilizarmos um intervalo de 2 minutos, teremos 90 dados classificados corretamente e 30 incorretamente. Porém, para um intervalo de 5 minutos, teremos 30 dados corretos e 270 dados incorretos.

Decandia et al., (2018) realizaram um estudo semelhante utilizando ovelhas a pasto e diferentes intervalos de captura de dados, variando de 5 segundos até 300 segundos. Diferente do nosso estudo, esses autores classificavam o intervalo de dados conforme o comportamento predominante (>50% dos dados) e não pelo registro da observação visual.

A primeira observação interessante refere-se ao momento da mudança de comportamento. Para isso, os autores dividiram o intervalo de coleta de dados em três grupos. No primeiro grupo, 100% dos dados pertenciam a um único comportamento, ou seja, não houve mudança de comportamento dentro do intervalo de tempo

registrado. No segundo grupo, entre 76-99% dos dados pertenciam a um comportamento e o restante a outro comportamento. Por fim, no terceiro grupo (50-75%), entre 50% e 75% dos dados pertenciam ao comportamento predominante, e o restante foi classificado de acordo com os demais comportamentos. Os autores identificaram que, quando a observação ocorria a cada 5 segundos, 98,8% das ocorrências apresentavam 100% dos dados do mesmo comportamento. Essa porcentagem diminuía à medida que o intervalo de coleta aumentava, indo para 97,4% e 93,3% para intervalos de 10 e 30 segundos, respectivamente, 88,3% para 60 segundos, 80,2% para 120 segundos e 60,2% para 300 segundos. Esses resultados demonstram que, quanto maior o intervalo, menor a probabilidade de 100% dos dados serem classificados corretamente.

A segunda observação relevante diz respeito à capacidade classificatória a cada intervalo de coleta. A acurácia relatada foi de 79,4% para 5 segundos, 86,4% para 10 segundos, 89,7% para 30 segundos, 88,9% para 60 segundos, 87,6% para 120 segundos, 84,7% para 180 segundos e 79,3% para 300 segundos. Assim, os melhores intervalos de captura foram 30, 60 e 120 segundos, superando até mesmo as coletas de 5 segundos. Os autores desencorajam intervalos maiores que 120 segundos. Contudo, em nosso trabalho, identificamos que a queda da acurácia entre 120 segundos e 300 segundos não foi tão intensa quanto a relatada pelos autores.

6.4.7 Observações Em Horários Fixos

Outra forma de realizar observações visuais em intervalos de tempo é utilizar exclusivamente os dados referentes àquela observação específica. Por exemplo, uma observação feita às 10:05:00 utilizaria unicamente os dados de 10:05:00. A principal vantagem dessa estratégia é a certeza de que os dados foram classificados corretamente, uma vez que estamos considerando apenas o momento exato da observação. No entanto, essa abordagem resulta em uma redução significativa na quantidade de dados disponíveis, o que pode comprometer a precisão e a robustez dos modelos. Além disso, uma desvantagem importante é que grande parte dos dados coletados não será utilizada, representando um desperdício de tempo e recursos, o que diminui a eficiência do processo de coleta e análise.

Tabela 25: Métricas de desempenho do modelo classificadores aplicado a 4 diferentes bancos de dados, divididos por coletas contínuas de dados e intervalos de coleta.

	Contínuo	2 Minutos	5 Minutos	10 Minutos
n dados	2027514	33784	13536	6751
Acurácia (%)	84.36	84.48	81.87	82.53
Precisão (%)	73.54	75.53	70.80	75.87
Recall (%)	67.73	66.17	59.66	59.90
F1-Score (%)	70.52	70.54	64.75	66.95

Podemos observar que não houve grande diferença nas métricas de desempenho entre as observações contínuas e as observações de 2 minutos, com uma interessante melhoria na precisão. Isso sugere que intervalos de 2 minutos podem ser uma alternativa viável, pois exigem menos esforço do observador, não afetam significativamente a classificação e ainda mantêm uma base de dados consistente. Por outro lado, para intervalos mais longos, como 5 e 10 minutos, a queda nas métricas foi mais acentuada, indicando que essas opções podem não ser ideais.

Provavelmente, essa diminuição no desempenho se deve à redução na quantidade de dados, que ficou abaixo dos volumes frequentemente relatados na literatura (Coelho Ribeiro et al., 2021; Decandia et al., 2018; Watanabe et al., 2021). De fato, a diminuição na quantidade de dados compromete a classificação dos modelos, como evidenciado por Althnian et al., (2021), que avaliaram algoritmos de aprendizado de máquina em dados médicos, com tamanhos variando de 1.040 a 245.057 registros, e por Persons et al., (2024), que analisaram o comportamento animal, com bancos de dados variando de 282 a 28.244 registros. Em ambos os casos, a redução na quantidade de dados resultou em uma queda na acurácia, precisão, recall e F1-Score.

6.5 Conclusão

Este estudo evidenciou o potencial da Zootecnia de Precisão na identificação automatizada de comportamentos ingestivos de bovinos, com ênfase na integração entre sensores vestíveis, observações visuais e técnicas avançadas de aprendizado de máquina. A construção de um banco de dados robusto, com mais de dois milhões de registros oriundos de diferentes sistemas de produção e categorias animais, permitiu análises consistentes quanto ao desempenho dos modelos classificadores.

A busca por hiperparâmetros demonstrou que, embora algoritmos como a Otimização Bayesiana e a Random Search apresentem resultados semelhantes em termos de acurácia, o tempo de processamento é um fator determinante na escolha da melhor estratégia, especialmente em contextos de grande volume de dados. Os Algoritmos Evolutivos, por sua vez, destacaram-se pela agilidade, mesmo que com desempenho ligeiramente inferior.

As técnicas de balanceamento de dados, em especial o SMOTE e o ADASYN, melhoraram as métricas de precisão e recall, embora não tenham superado a acurácia dos dados originais. A técnica NearMiss, por outro lado, mostrou desempenho insatisfatório, sugerindo que sua aplicação deve ser criteriosa, especialmente em bancos com sobreposição de comportamentos.

Quanto ao local de fixação dos sensores, os dispositivos instalados na nuca apresentaram melhor desempenho classificatório do que os fixados em colares, especialmente em cenários de maior complexidade comportamental. Ainda assim, aspectos práticos, como facilidade de uso e adaptação ao manejo, devem ser considerados para futuras aplicações em campo.

Por fim, observações visuais contínuas resultaram em melhores métricas de avaliação para modelos classificadores, mas os intervalos de até 2 minutos demonstraram ser uma alternativa viável, equilibrando precisão, volume de dados e esforço de observação. A redução drástica da base de dados, como nos intervalos de 5 e 10 minutos, impactou negativamente as métricas, reforçando a importância de manter volumes mínimos adequados de dados para garantir a eficácia dos modelos.

Assim, os resultados obtidos neste capítulo não apenas validam o uso de sensores vestíveis e algoritmos no monitoramento comportamental de bovinos, como também fornecem diretrizes metodológicas valiosas para futuros estudos e aplicações práticas em sistemas produtivos, contribuindo para a consolidação da Zootecnia de Precisão como ferramenta estratégica no manejo animal moderno.

7. CONCLUSÃO GERAL

A presente tese representou um avanço significativo na aplicação da Zootecnia de Precisão ao propor e validar metodologias robustas para a detecção automatizada do comportamento ingestivo de bovinos. Ao integrar sensores vestíveis personalizados, protocolos experimentais detalhados e técnicas avançadas de aprendizado de máquina, o estudo respondeu a desafios técnicos, metodológicos e analíticos frequentemente negligenciados em pesquisas anteriores.

Entre os principais destaques está o desenvolvimento de sensores baseados em microcontroladores ESP32 acoplados a acelerômetros e giroscópios (MPU-6050), otimizados para coleta em condições reais de campo. A instrumentação foi validada em oito cenários distintos de produção animal, abrangendo diferentes sistemas (confinamento, pasto, compost barn, tie-stall etc.) e categorias fisiológicas, totalizando aproximadamente dois milhões de registros comportamentais, um volume superior ao encontrado na literatura.

A modelagem computacional contemplou abordagens comparativas entre algoritmos amplamente utilizados, como RF, LGB, KNN e ANN. Para maximizar o desempenho, diferentes estratégias de busca por hiperparâmetros foram testadas (Random Search, Bayesian Search e Algoritmos Evolutivos), assim como técnicas de balanceamento de classes (SMOTE, ADASYN, NearMiss, Random Undersampling), fundamentais para lidar com a distribuição desigual dos comportamentos de alimentação, ruminação e ócio.

A tese também aprofundou a influência de fatores metodológicos críticos como o local de fixação dos sensores (nuca vs. colar), o intervalo de tempo para a coleta dos dados, e a estratégia de observação visual. Foi demonstrado que essas decisões impactam diretamente a qualidade dos dados e, consequentemente, a acurácia dos modelos. Outro ponto relevante foi a ênfase na validação externa, garantindo que os modelos treinados apresentassem desempenho consistente mesmo em cenários distintos dos dados de treinamento — uma limitação metodológica comum em estudos anteriores.

Além da contribuição técnica, a tese oferece diretrizes metodológicas aplicáveis a futuras pesquisas e à indústria, promovendo maior reprodutibilidade e padronização

na identificação automatizada de comportamentos ingestivos. Os resultados indicam que é possível obter modelos preditivos robustos e generalizáveis, desde que haja rigor na coleta, curadoria e validação dos dados.

REFERÊNCIAS

- Abeni, F., & Galli, A. (2017). Monitoring cow activity and rumination time for an early detection of heat stress in dairy cow. *International Journal of Biometeorology*, 61(3), 417–425. <https://doi.org/10.1007/s00484-016-1222-z>
- Aiken, V. C. F., Dórea, J. R. R., Acedo, J. S., de Sousa, F. G., Dias, F. G., & Rosa, G. J. de M. (2019). Record linkage for farm-level data analytics: Comparison of deterministic, stochastic and machine learning methods. *Computers and Electronics in Agriculture*, 163, 104857. <https://doi.org/10.1016/j.compag.2019.104857>
- Althnian, A., AlSaeed, D., Al-Baity, H., Samha, A., Dris, A. Bin, Alzakari, N., Abou Elwafa, A., & Kurdi, H. (2021). Impact of dataset size on classification performance: An empirical evaluation in the medical domain. *Applied Sciences (Switzerland)*, 11(2), 1–18. <https://doi.org/10.3390/app11020796>
- Alwosheel, A., van Cranenburgh, S., & Chorus, C. G. (2018). Is your dataset big enough? Sample size requirements when using artificial neural networks for discrete choice analysis. *Journal of Choice Modelling*, 28, 167–182. <https://doi.org/10.1016/j.jocm.2018.07.002>
- Andrew, N. (2018). *Machine Learning Yearning*. deeplearning.ai.
- Anglart, D., Emanuelson, U., Rönnegård, L., & Hallén Sandgren, C. (2021). Detecting and predicting changes in milk homogeneity using data from automatic milking systems. *Journal of Dairy Science*, 104(10), 11009–11017. <https://doi.org/10.3168/jds.2021-20517>
- Arablouei, R., Augusto, F., Alvarenga, P., Bishop-Hurley, G. J., Wang, L., Alvarenga, F. A. P., & Bishop-Hurley, G. J. (2021). *Animal Behavior Classification via Accelerometry Data and Recurrent Neural Networks*. <https://doi.org/10.48550/arXiv.2111.12843>
- Arıkan, İ., Ayav, T., Seçkin, A. Ç., & Soygazi, F. (2023). Estrus Detection and Dairy Cow Identification with Cascade Deep Learning for Augmented Reality-Ready Livestock Farming. *Sensors*, 23(24). <https://doi.org/10.3390/s23249795>
- Bai, Z., Gu, J., Zhu, R., Yao, X., Kang, L., & Ge, J. (2022). Discrimination of Minced Mutton Adulteration Based on Sized-Adaptive Online NIRS Information and 2D Conventional Neural Network. *Foods*, 11(19), 2977. <https://doi.org/10.3390/foods11192977>
- Barwick, J., Lamb, D. W., Dobos, R., Welch, M., & Trotter, M. (2018). Categorising sheep activity using a tri-axial accelerometer. *Computers and Electronics in Agriculture*, 145, 289–297. <https://doi.org/10.1016/j.compag.2018.01.007>
- Benjamin, M., & Yik, S. (2019). Precision Livestock Farming in Swine Welfare: A Review for Swine Practitioners. *Animals*, 9(4), 133. <https://doi.org/10.3390/ani9040133>

Berckmans, D. (2014). Precision livestock farming technologies for welfare management in intensive livestock systems. In *Rev. sci. tech. Off. int. Epiz* (Vol. 33, Issue 1). www.welfarequality.net

Bewley, J. M., Russell, R. A., Dolecheck, K. A., Borchers, M. R., Stone, A. E., Wadsworth, B. A., Mayo, L. M., & Tsai, I.-C. (2015). *Western Dairy Management Conference Precision Dairy Monitoring Opportunities, Limitations, and Considerations*.

Breiman, L. (2001). *Random Forests* (Vol. 45).

Cairo, F. C., Pereira, L. G. R., Campos, M. M., Tomich, T. R., Coelho, S. G., Lage, C. F. A., Fonseca, A. P., Borges, A. M., Alves, B. R. C., & Dorea, J. R. R. (2020). Applying machine learning techniques on feeding behavior data for early estrus detection in dairy heifers. *Computers and Electronics in Agriculture*, 179. <https://doi.org/10.1016/j.compag.2020.105855>

Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: Synthetic Minority Over-sampling Technique. In *Journal of Artificial Intelligence Research* (Vol. 16).

Chelotti, J. O., Vanrell, S. R., Martinez-Rau, L. S., Galli, J. R., Utsumi, S. A., Planisich, A. M., Almirón, S. A., Milone, D. H., Giovanini, L. L., & Rufiner, H. L. (2023). Using segment-based features of jaw movements to recognise foraging activities in grazing cattle. *Biosystems Engineering*, 229, 69–84. <https://doi.org/10.1016/j.biosystemseng.2023.03.014>

Chen, J. M., Schütz, K. E., & Tucker, C. B. (2016). Technical note: Comparison of instantaneous sampling and continuous observation of dairy cattle behavior in freestall housing. *Journal of Dairy Science*, 99(10), 8341–8346. <https://doi.org/10.3168/jds.2016-11351>

Chung, H., Zhang, X., Jung, S., Zhang, Z., & Choi, C. Y. (2022). Application of machine-learned metadata-driven model for dairy barn ventilation simulation. *Computers and Electronics in Agriculture*, 202, 107350. <https://doi.org/10.1016/j.compag.2022.107350>

Coelho Ribeiro, L. A., Bresolin, T., Rosa, G. J. de M., Rume Casagrande, D., Danes, M. de A. C., & Dórea, J. R. R. (2021). Disentangling data dependency using cross-validation strategies to evaluate prediction quality of cattle grazing activities using machine learning algorithms and wearable sensor data. *Journal of Animal Science*, 99(9). <https://doi.org/10.1093/jas/skab206>

Condon, D. (2019). *Performance of Artificial Neural Networks on Small Structured Datasets*.

Cover, T. M., & Hart, P. E. (1967). Nearest Neighbor Pattern Classification. *IEEE TRANSACTIONS ON INFORMATION THEORY*, 24(1), 335–342. <https://doi.org/10.1109/TIT.1967.1053964>

Day, W. (2005). Engineering precision into variable biological systems. In *Annals of Applied Biology* (Vol. 146).

Decandia, M., Giovanetti, V., Molle, G., Acciaro, M., Mameli, M., Cabiddu, A., Cossu, R., Serra, M. G., Manca, C., Rassu, S. P. G., & Dimauro, C. (2018). The effect of different time epoch settings on the classification of sheep behaviour using tri-axial accelerometry. *Computers and Electronics in Agriculture*, *154*, 112–119. <https://doi.org/10.1016/j.compag.2018.09.002>

Dissanayake, O., McPherson, S. E., Allyndree, J., Kennedy, E., Cunningham, P., & Riaboff, L. (2024). *Evaluating ROCKET and Catch22 features for calf behaviour classification from accelerometer data using Machine Learning models*. <http://arxiv.org/abs/2404.18159>

Eikelboom, J. A. J., Wind, J., van de Ven, E., Kenana, L. M., Schroder, B., de Knecht, H. J., van Langevelde, F., & Prins, H. H. T. (2019). Improving the precision and accuracy of animal population estimates with aerial image object detection. *Methods in Ecology and Evolution*, *10*(11), 1875–1887. <https://doi.org/10.1111/2041-210X.13277>

Fan, B., Zhu, R., He, D., Wang, S., Cui, X., & Yao, X. (2022). Evaluation of Mutton Adulteration under the Effect of Mutton Flavour Essence Using Hyperspectral Imaging Combined with Machine Learning and Sparrow Search Algorithm. *Foods*, *11*(15), 2278. <https://doi.org/10.3390/foods11152278>

Fernández, A., García, S., Herrera, F., & Chawla, N. V. (2018). SMOTE for Learning from Imbalanced Data: Progress and Challenges, Marking the 15-year Anniversary. In *Journal of Artificial Intelligence Research* (Vol. 61).

Friedman, J. H. (2021). Greedy Function Approximation: A Gradient Boosting Machine. *The Annals of Statistics*, *29*(5), 1189–1232.

Fuentes, A., Han, S., Nasir, M. F., Park, J., Yoon, S., & Park, D. S. (2023). Multiview Monitoring of Individual Cattle Behavior Based on Action Recognition in Closed Barns Using Deep Learning. *Animals*, *13*(12). <https://doi.org/10.3390/ani13122020>

Gabriel, A., & Gandorfer, M. (2023). Adoption of digital technologies in agriculture—an inventory in a european small-scale farming region. *Precision Agriculture*, *24*(1), 68–91. <https://doi.org/10.1007/s11119-022-09931-1>

Gallitto, G., Englert, R., Kincses, B., Kotikalapudi, R., Li, J., Hoffschlag, K., Bingel, U., & Spisak, T. (2025). External validation of machine learning models—registered models and adaptive sample splitting. *GigaScience*, *14*. <https://doi.org/10.1093/gigascience/giaf036>

Gladden, N., Cuthbert, E., Ellis, K., & McKeegan, D. (2020a). Use of a tri-axial accelerometer can reliably detect play behaviour in newborn calves. *Animals*, *10*(7), 1–19. <https://doi.org/10.3390/ani10071137>

Gladden, N., Cuthbert, E., Ellis, K., & McKeegan, D. (2020b). Use of a Tri-Axial Accelerometer Can Reliably Detect Play Behaviour in Newborn Calves. *Animals*, 10(7), 1137. <https://doi.org/10.3390/ani10071137>

Gong, Z., Zhong, P., & Hu, W. (2019). *Diversity in Machine Learning*. <https://doi.org/10.1109/ACCESS.2017.DOI>

Goodfellow, I. (2016). *NIPS 2016 Tutorial: Generative Adversarial Networks*. <http://arxiv.org/abs/1701.00160>

Hasan, M., Kotov, A., Idalski Carcone, A., Dong, M., Naar, S., & Brogan Hartlieb, K. (2016). A study of the effectiveness of machine learning methods for classification of clinical interview fragments into a large number of categories. *Journal of Biomedical Informatics*, 62, 21–31. <https://doi.org/10.1016/j.jbi.2016.05.004>

Hauschild, A. C., Lemanczyk, M., Matschinske, J., Frisch, T., Zolotareva, O., Holzinger, A., Baumbach, J., & Heider, D. (2022). Federated Random Forests can improve local performance of predictive models for various healthcare applications. *Bioinformatics*, 38(8), 2278–2286. <https://doi.org/10.1093/bioinformatics/btac065>

He, H., Bai, Y., Garcia, E., & Li, S. (2008). *ADASYN: Adaptive Synthetic Sampling Approach for Imbalanced Learning*. IEEE.

Henrique Silva, L. (2021). *Dissertacao Lázaro Henrique da Silva*. Federal University of Lavras.

Herlin, A., Brunberg, E., Hultgren, J., Högberg, N., Rydberg, A., & Skarin, A. (2021). Animal welfare implications of digital tools for monitoring and management of cattle and sheep on pasture. In *Animals* (Vol. 11, Issue 3, pp. 1–20). MDPI AG. <https://doi.org/10.3390/ani11030829>

Hidayaturrohman, Q. A., & Hanada, E. (2025). A Comparative Analysis of Hyper-Parameter Optimization Methods for Predicting Heart Failure Outcomes. *Applied Sciences (Switzerland)*, 15(6). <https://doi.org/10.3390/app15063393>

Hussain, S., Oyelere, S. S., Marefat, A., Joloudari, J. H., & Nematollahi, M. A. (2022). *Effective Class-Imbalance learning based on SMOTE and Convolutional Neural Networks*. <https://www.researchgate.net/publication/363269818>

Jawad, H. M., Nordin, R., Gharghan, S. K., Jawad, A. M., & Ismail, M. (2017). Energy-efficient wireless sensor networks for precision agriculture: A review. In *Sensors (Switzerland)* (Vol. 17, Issue 8). MDPI AG. <https://doi.org/10.3390/s17081781>

Ji, B., Banhazi, T., Phillips, C. J. C., Wang, C., & Li, B. (2022). A machine learning framework to predict the next month's daily milk yield, milk composition and milking frequency for cows in a robotic dairy farm. *Biosystems Engineering*, 216, 186–197. <https://doi.org/10.1016/j.biosystemseng.2022.02.013>

Jiang, B., Tang, W., Cui, L., & Deng, X. (2023). Precision Livestock Farming Research: A Global Scientometric Review. In *Animals* (Vol. 13, Issue 13). Multidisciplinary Digital Publishing Institute (MDPI). <https://doi.org/10.3390/ani13132096>

Jiang, J., Zhang, C., Ke, L., Hayes, N., Zhu, Y., Qiu, H., Zhang, B., Zhou, T., & Wei, G. W. (2025). A review of machine learning methods for imbalanced data challenges in chemistry. In *Chemical Science* (Vol. 16, Issue 18, pp. 7637–7658). Royal Society of Chemistry. <https://doi.org/10.1039/d5sc00270b>

Ke, G., Meng, Q., Finley, T., Wang, T., Chen, W., Ma, W., Ye, Q., & Liu, T.-Y. (2017). *LightGBM: A Highly Efficient Gradient Boosting Decision Tree*. <https://github.com/Microsoft/LightGBM>.

Khanh, P. C. P., Tran, D. T., Duong, V. T., Thinh, N. H., & Tran, D. N. (2020). The new design of cows' behavior classifier based on acceleration data and proposed feature set. *Mathematical Biosciences and Engineering*, 17(4), 2760–2780. <https://doi.org/10.3934/MBE.2020151>

Kim, H. T., Ikeda, Y., & Choi, H. L. (2005). The Identification of Japanese Black Cattle by Their Faces. *Asian-Australasian Journal of Animal Sciences*, 18(6), 868–872. <https://doi.org/10.5713/ajas.2005.868>

Koskela, O., Benitez Pereira, L. S., Pölönen, I., Aronen, I., & Kunttu, I. (2022). Deep learning image recognition of cow behavior and an open data set acquired near an automatic milking robot. *Agricultural and Food Science*. <https://doi.org/10.23986/afsci.111665>

Kraft, M., Bernhardt, H., Brunsch, R., Büscher, W., Colangelo, E., Graf, H., Marquering, J., Tapken, H., Toppel, K., Westerkamp, C., & Ziron, M. (2022). Can Livestock Farming Benefit from Industry 4.0 Technology? Evidence from Recent Study. *Applied Sciences (Switzerland)*, 12(24). <https://doi.org/10.3390/app122412844>

Laberge, B., & Rousseau, A. N. (2017). Rethinking environment control strategy of confined animal housing systems through precision livestock farming. In *Biosystems Engineering* (Vol. 155, pp. 96–123). Academic Press. <https://doi.org/10.1016/j.biosystemseng.2016.12.005>

Ladds, M. A., Thompson, A. P., Slip, D. J., Hocking, D. P., & Harcourt, R. G. (2016). Seeing it all: Evaluating supervised machine learning methods for the classification of diverse otariid behaviours. *PLoS ONE*, 11(12). <https://doi.org/10.1371/journal.pone.0166898>

Ledoux, D., Veissier, I., Meunier, B., Gelin, V., Richard, C., Kiefer, H., Jammes, H., Foucras, G., & de Boyer des Roches, A. (2023). Combining accelerometers and direct visual observations to detect sickness and pain in cows of different ages submitted to systemic inflammation. *Scientific Reports*, 13(1). <https://doi.org/10.1038/s41598-023-27884-x>

Liashchynskiy, P., & Liashchynskiy, P. (2019). *Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS*. <https://doi.org/10.48550/arXiv.1912.06059>

Liu, D., Ma, Y., Yu, S., & Zhang, C. (2023). Image based beef and lamb slice authentication using convolutional neural networks. *Meat Science*, 195, 108997. <https://doi.org/10.1016/j.meatsci.2022.108997>

Lo, J. E., Kang, E. Y. C., Chen, Y. N., Hsieh, Y. T., Wang, N. K., Chen, T. C., Chen, K. J., Wu, W. C., Hwang, Y. S., Lo, F. S., & Lai, C. C. (2021). Data Homogeneity Effect in Deep Learning-Based Prediction of Type 1 Diabetic Retinopathy. *Journal of Diabetes Research*, 2021. <https://doi.org/10.1155/2021/2751695>

Lorand, C., Bouet, L., Devineau, O., Chimienti, M., Evans, A. L., Callahan, P., Beckel, M., Laske, T. G., & Eriksen, A. (2025). A supervised model to identify wolf behavior from tri-axial acceleration. *Animal Biotelemetry*, 13(1). <https://doi.org/10.1186/s40317-025-00400-w>

Mahdavian, A., Minaei, S., Marchetto, P. M., Almasganj, F., Rahimi, S., & Yang, C. (2021). Acoustic features of vocalization signal in poultry health monitoring. *Applied Acoustics*, 175. <https://doi.org/10.1016/j.apacoust.2020.107756>

Manfrè, C., Battini, M., Simonetto, A., Contiero, B., Serva, L., Mattiello, S., Ntalampiras, S., Normando, S., & Brscic, M. (2024). A methodological approach to compare continuous and instantaneous sampling and two methods to deal with animals out of sight on dairy cattle behavior and interaction with their calf in the first hours post-partum. *Frontiers in Veterinary Science*, 11. <https://doi.org/10.3389/fvets.2024.1360239>

Marumo, J. L., Lusseau, D., Speakman, J. R., Mackie, M., Byar, A. Y., Cartwright, W., & Hambly, C. (2024). Behavioural variability, physical activity, rumination time, and milk characteristics of dairy cattle in response to regrouping. *Animal*, 18(3). <https://doi.org/10.1016/j.animal.2024.101094>

Mauny, S., Kwon, J., Friggens, N. C., Duvaux-Ponter, C., & Taghipoor, M. (2025). A pipeline with pre-processing options to detect behaviour from accelerometer data using Machine Learning tested on dairy goats. *Peer Community Journal*, 5, 000–000. <https://doi.org/10.24072/pci>

Mcculloch, W. S., & Pitts, W. (1943). A LOGICAL CALCULUS OF THE IDEAS IMMANENT IN NERVOUS ACTIVITY. In *BULLETIN OF MATHEMATICAL BIOPHYSICS* (Vol. 5).

McWilliams, C. J., Schwanke, A. J., & DeVries, T. J. (2022). Is greater milk production associated with dairy cows who have a greater probability of ruminating while lying down? *JDS Communications*, 3(1), 66–71. <https://doi.org/10.3168/jdsc.2021-0159>

Mitlöhner, F. M., Morrow-Tesch, J. L., Wilson, S. C., Dailey, J. W., & McGlone, J. J. (2001). Behavioral sampling techniques for feedlot cattle. *Journal of Animal Science*, 79(5), 1189–1193. <https://doi.org/10.2527/2001.7951189x>

Mladenova, T., Valova, I., Evstatiev, B., Valov, N., Varlyakov, I., Markov, T., Stoycheva, S., Mondeshka, L., & Markov, N. (2024). Evaluation of the Efficiency of Machine Learning Algorithms for Identification of Cattle Behavior Using Accelerometer and Gyroscope Data. *AgriEngineering*, 6(3), 2179–2197. <https://doi.org/10.3390/agriengineering6030128>

Morota, G., Ventura, R. V, Silva, F. F., Koyama, M., & Fernando, S. C. (2018). *BIG DATA ANALYTICS AND PRECISION ANIMAL AGRICULTURE SYMPOSIUM Machine learning and data mining advance predictive big data analysis in precision animal agriculture* 1. <https://doi.org/10.1093/jas/sky014/4828311>

Morrone, S., Dimauro, C., Gambella, F., & Cappai, M. G. (2022). Industry 4.0 and Precision Livestock Farming (PLF): An up to Date Overview across Animal Productions. In *Sensors* (Vol. 22, Issue 12). MDPI. <https://doi.org/10.3390/s22124319>

Muzzo, B. I., Bladen, K., Perea, A., Nyamuryekung'e, S., & Villalba, J. J. (2025). Multi-Sensor Integration and Machine Learning for High-Resolution Classification of Herbivore Foraging Behavior. *Animals*, 15(7). <https://doi.org/10.3390/ani15070913>

Nayan, N. M., Islam, A., Islam, M. U., Ahmed, E., Hossain, M. M., & Alam, M. Z. (2023). SMOTE Oversampling and Near Miss Undersampling Based Diabetes Diagnosis from Imbalanced Dataset with XAI Visualization. *Proceedings - IEEE Symposium on Computers and Communications*, 2023-July. <https://doi.org/10.1109/ISCC58397.2023.10218281>

Neethirajan, S., & Kemp, B. (2021). Digital Livestock Farming. In *Sensing and Bio-Sensing Research* (Vol. 32). Elsevier B.V. <https://doi.org/10.1016/j.sbsr.2021.100408>

Nguyen, Q. T., Fouchereau, R., Frénod, E., Gerard, C., & Sincholle, V. (2020). Comparison of forecast models of production of dairy cows combining animal and diet parameters. *Computers and Electronics in Agriculture*, 170. <https://doi.org/10.1016/j.compag.2020.105258>

Nguyen, T., Khadka, R., Phan, N., Yazidi, A., Halvorsen, P., & Riegler, M. A. (2022). *Combining datasets to increase the number of samples and improve model fitting*. <http://arxiv.org/abs/2210.05165>

Norring, M., Valros, A., & Munksgaard, L. (2012). Milk yield affects time budget of dairy cows in tie-stalls. *Journal of Dairy Science*, 95(1), 102–108. <https://doi.org/10.3168/jds.2010-3458>

Pandorfi, H., Almeida, G. L. P., & Guiselini, C. (2012). Precision animal production: basic principles and news in the swine production. In *Rev. Bras. Saúde Prod. Anim* (Issue 2). <http://www.rbspa.ufba.br>

Pereira, G. M., Sharpe, K. T., & Heins, B. J. (2021). Evaluation of the RumiWatch system as a benchmark to monitor feeding and locomotion behaviors of grazing dairy cows. *Journal of Dairy Science*, 104(3), 3736–3750. <https://doi.org/10.3168/jds.2020-18952>

Perez Marquez, H. J., Ambrose, D. J., & Bench, C. J. (2023). Behavioral changes to detect estrus using ear-sensor accelerometer compared to in-line milk progesterone in a commercial dairy herd. *Frontiers in Animal Science*, 4. <https://doi.org/10.3389/fanim.2023.1149085>

Persons, J., Smith, A., & Johnson, R. (2024). Analysis of grazing cattle behavior: comparison between full and reduced datasets. *Journal of Animal Behavior Studies*, 58(3), 123–135.

Pinto, D. L., Selli, A., Tulpan, D., Andrietta, L. T., Garbossa, P. L. M., Voort, G. Vander, Munro, J., McMorris, M., Alves, A. A. C., Carneiro, R., Poleti, M. D., Balieiro, J. C. de C., & Ventura, R. V. (2023). Image feature extraction via local binary patterns for marbling score classification in beef cattle using tree-based algorithms. *Livestock Science*, 267, 105152. <https://doi.org/10.1016/j.livsci.2022.105152>

Polikarpus, A., Kaart, T., Mootse, H., De Rosa, G., & Arney, D. (2015). Influences of various factors on cows' entrance order into the milking parlour. *Applied Animal Behaviour Science*, 166(1), 20–24. <https://doi.org/10.1016/j.applanim.2015.02.016>

Probst, P., & Bischl, B. (2019). Tunability: Importance of Hyperparameters of Machine Learning Algorithms. In *Journal of Machine Learning Research* (Vol. 20). <http://jmlr.org/papers/v20/18-444.html>.

Raynor, E. J., Derner, J. D., Soder, K. J., & Augustine, D. J. (2021). Noseband sensor validation and behavioural indicators for assessing beef cattle grazing on extensive pastures. *Applied Animal Behaviour Science*, 242, 105402. <https://doi.org/10.1016/j.applanim.2021.105402>

Riaboff, L., Shalloo, L., Smeaton, A. F., Couvreur, S., Madouasse, A., & Keane, M. T. (2022). Predicting livestock behaviour using accelerometers: A systematic review of processing techniques for ruminant behaviour prediction from raw accelerometer data. In *Computers and Electronics in Agriculture* (Vol. 192). Elsevier B.V. <https://doi.org/10.1016/j.compag.2021.106610>

Romanzini, E. P., Watanabe, R. N., Fonseca, N. V. B., Berça, A. S., Brito, T. R., Bernardes, P. A., Munari, D. P., & Reis, R. A. (2022). Modern livestock farming under tropical conditions using sensors in grazing systems. *Scientific Reports*, 12(1), 2654. <https://doi.org/10.1038/s41598-022-06650-5>

Rutten, C. J., Velthuis, A. G. J., Steeneveld, W., & Hogeveen, H. (2013). Invited review: Sensors to support health management on dairy farms. In *Journal of Dairy Science* (Vol. 96, Issue 4, pp. 1928–1952). <https://doi.org/10.3168/jds.2012-6107>

Sadeghi, M., Banakar, A., Minaei, S., Orooji, M., Shoushtari, A., & Li, G. (2023). Early Detection of Avian Diseases Based on Thermography and Artificial Intelligence. *Animals*, 13(14). <https://doi.org/10.3390/ani13142348>

Salau, J., Haas, J. H., Junge, W., & Thaller, G. (2020). Determination of Body Parts in Holstein Friesian Cows Comparing Neural Networks and k Nearest Neighbour Classification. *Animals*, 11(1), 50. <https://doi.org/10.3390/ani11010050>

Salau, J., & Krieter, J. (2020). Instance Segmentation with Mask R-CNN Applied to Loose-Housed Dairy Cows in a Multi-Camera Setting. *Animals*, 10(12), 2402. <https://doi.org/10.3390/ani10122402>

Schmeling, L., Elmamooz, G., Hoang, P. T., Kozar, A., Nicklas, D., Sünkel, M., Thurner, S., & Rauch, E. (2021). Training and validating a machine learning model for the sensor-based monitoring of lying behavior in dairy cows on pasture and in the barn. *Animals*, 11(9). <https://doi.org/10.3390/ani11092660>

Shafiullah, A. Z., Werner, J., Kennedy, E., Leso, L., O'brien, B., & Umstätter, C. (2019). Machine learning based prediction of insufficient herbage allowance with automated feeding behaviour and activity data. *Sensors (Switzerland)*, 19(20). <https://doi.org/10.3390/s19204479>

Sharma, A., Jain, A., Gupta, P., & Chowdary, V. (2021). Machine Learning Applications for Precision Agriculture: A Comprehensive Review. In *IEEE Access* (Vol. 9, pp. 4843–4873). Institute of Electrical and Electronics Engineers Inc. <https://doi.org/10.1109/ACCESS.2020.3048415>

Shelke, M., Shandilya, & Deshmukh. (2017). A Review on Imbalanced Data Handling Using Undersampling and Oversampling Technique. *International Journal of Recent Trends in Engineering and Research*, 3(4), 444–449. <https://doi.org/10.23883/ijrter.2017.3168.0uwxm>

Shin, S., Lee, Y., Kim, S., Choi, S., Kim, J. G., & Lee, K. (2021). Rapid and non-destructive spectroscopic method for classifying beef freshness using a deep spectral network fused with myoglobin information. *Food Chemistry*, 352, 129329. <https://doi.org/10.1016/j.foodchem.2021.129329>

Shine, P., Murphy, M. D., Upton, J., & Scully, T. (2018). Machine-learning algorithms for predicting on-farm direct water and electricity consumption on pasture based dairy farms. *Computers and Electronics in Agriculture*, 150, 74–87. <https://doi.org/10.1016/j.compag.2018.03.023>

Simanungkalit, G., Barwick, J., Cowley, F., Dobos, R., & Hegarty, R. (2021). A pilot study using accelerometers to characterise the licking behaviour of penned cattle at a mineral block supplement. *Animals*, 11(4). <https://doi.org/10.3390/ani11041153>

Soares, V. H. A., Ponti, M. A., Gonçalves, R. A., & Campello, R. J. G. B. (2021). Cattle counting in the wild with geolocated aerial images in large pasture areas. *Computers and Electronics in Agriculture*, 189, 106354. <https://doi.org/10.1016/j.compag.2021.106354>

Spoliansky, R., Edan, Y., Parmet, Y., & Halachmi, I. (2016). Development of automatic body condition scoring using a low-cost 3-dimensional Kinect camera. *Journal of Dairy Science*, 99(9), 7714–7725. <https://doi.org/10.3168/jds.2015-10607>

SUNESH, BALHARA, A. K., DAHIYA, N. K., HIMANSHU, SINGH, R. P., & RUHIL, A. P. (2022). Machine learning algorithms for predicting peak yield in buffaloes using linear traits. *The Indian Journal of Animal Sciences*, 92(8), 1013–1019. <https://doi.org/10.56093/ijans.v92i8.122008>

Tahfim, S. A. S., & Chen, Y. (2024). Comparison of Cluster-Based Sampling Approaches for Imbalanced Data of Crashes Involving Large Trucks. *Information (Switzerland)*, 15(3). <https://doi.org/10.3390/info15030145>

Tantithamthavorn, C., Hassan, A. E., & Matsumoto, K. (2018). *The Impact of Class Rebalancing Techniques on the Performance and Interpretation of Defect Prediction Models*. <http://arxiv.org/abs/1801.10269>

van der Heide, E. M. M., Veerkamp, R. F., van Pelt, M. L., Kamphuis, C., Athanasiadis, I., & Ducro, B. J. (2019). Comparing regression, naive Bayes, and random forest methods in the prediction of individual survival to second lactation in Holstein cattle. *Journal of Dairy Science*, 102(10), 9409–9421. <https://doi.org/10.3168/jds.2019-16295>

Wang, J., Lovarelli, D., Rota, N., Shen, M., Lu, M., & Guarino, M. (2022). The Potentialities of Machine Learning for Cow-Specific Milking: Automatically Setting Variables in Milking Machines. *Animals*, 12(13). <https://doi.org/10.3390/ani12131614>

Wang, L., Arablouei, R., Alvarenga, F. A. P., & Bishop-Hurley, G. J. (2023). Classifying animal behavior from accelerometry data via recurrent neural networks. *Computers and Electronics in Agriculture*, 206. <https://doi.org/10.1016/j.compag.2023.107647>

Wang, N., Zhang, N., & Wang, M. (2006). Wireless sensors in agriculture and food industry - Recent development and future perspective. In *Computers and Electronics in Agriculture* (Vol. 50, Issue 1, pp. 1–14). <https://doi.org/10.1016/j.compag.2005.09.003>

Warner, D., Vasseur, E., Lefebvre, D. M., & Lacroix, R. (2020). A machine learning based decision aid for lameness in dairy herds using farm-based records. *Computers and Electronics in Agriculture*, 169. <https://doi.org/10.1016/j.compag.2019.105193>

Watanabe, R. N., Bernardes, P. A., Romanzini, E. P., Teobaldo, R. W., Reis, R. A., Munari, D. P., Braga, L. G., & Brito, T. R. (2021). Strategy to predict high and low frequency behaviors using triaxial accelerometers in grazing of beef cattle. *Animals*, 11(12). <https://doi.org/10.3390/ani11123438>

Williams, M., & Zhan Lai, S. (2022). Classification of dairy cow excretory events using a tail-mounted accelerometer. *Computers and Electronics in Agriculture*, 199. <https://doi.org/10.1016/j.compag.2022.107187>

Wilson, O., Schoeman, D., Bradley, A., & Clemente, C. (2025). Practical guidelines for validation of supervised machine learning models in accelerometer-based animal behaviour classification. In *Journal of Animal Ecology*. John Wiley and Sons Inc. <https://doi.org/10.1111/1365-2656.70054>

Wongvorachan, T., He, S., & Bulut, O. (2023). A Comparison of Undersampling, Oversampling, and SMOTE Methods for Dealing with Imbalanced Classification in Educational Data Mining. *Information (Switzerland)*, 14(1). <https://doi.org/10.3390/info14010054>

Xu, B., Wang, W., Falzon, G., Kwan, P., Guo, L., Chen, G., Tait, A., & Schneider, D. (2020). Automated cattle counting using Mask R-CNN in quadcopter vision system. *Computers and Electronics in Agriculture*, 171, 105300. <https://doi.org/10.1016/j.compag.2020.105300>

Xu, W., van Knegsel, A. T. M., Vervoort, J. J. M., Bruckmaier, R. M., van Hoeij, R. J., Kemp, B., & Saccenti, E. (2019a). Prediction of metabolic status of dairy cows in early lactation with on-farm cow data and machine learning algorithms. *Journal of Dairy Science*, 102(11), 10186–10201. <https://doi.org/10.3168/jds.2018-15791>

Xu, W., van Knegsel, A. T. M., Vervoort, J. J. M., Bruckmaier, R. M., van Hoeij, R. J., Kemp, B., & Saccenti, E. (2019b). Prediction of metabolic status of dairy cows in early lactation with on-farm cow data and machine learning algorithms. *Journal of Dairy Science*, 102(11), 10186–10201. <https://doi.org/10.3168/jds.2018-15791>

Yang, C., Fridgeirsson, E. A., Kors, J. A., Reps, J. M., & Rijnbeek, P. R. (2024). Impact of random oversampling and random undersampling on the performance of prediction models developed using observational health data. *Journal of Big Data*, 11(1). <https://doi.org/10.1186/s40537-023-00857-7>

Yang, Y., Khorshidi, H. A., & Aickelin, U. (2024). A review on over-sampling techniques in classification of multi-class imbalanced datasets: insights for medical problems. In *Frontiers in Digital Health* (Vol. 6). Frontiers Media SA. <https://doi.org/10.3389/fdgth.2024.1430245>

Yigit, T., Han, F., Rankins, E., Yi, J., McKeever, K. H., & Malinowski, K. (2022). Wearable Inertial Sensor-Based Limb Lameness Detection and Pose Estimation for Horses. *IEEE Transactions on Automation Science and Engineering*, 19(3), 1365–1379. <https://doi.org/10.1109/TASE.2022.3157793>

Yu, H., Deng, J., Nathan, R., Kröschel, M., Pekarsky, S., Li, G., & Klaassen, M. (2021). An evaluation of machine learning classifiers for next-generation, continuous-ethogram smart trackers. *Movement Ecology*, 9(1). <https://doi.org/10.1186/s40462-021-00245-x>

Zhang, J., & Mani, I. (2023). *kNN Approach to Unbalanced Data Distributions: A Case Study involving Information Extraction*. National Research Council Canada = Conseil national de recherches Canada.