

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS AGRÁRIAS
CURSO DE ZOOTECNIA**

MEIRE LUIZA WIRTH

**AVALIAÇÃO DO USO DE SENSORES NA PREDIÇÃO DO
COMPORTAMENTO DE BOVINOS CONFINADOS**

FLORIANÓPOLIS - SC

2023

**UNIVERSIDADE FEDERAL DE SANTA CATARINA
CENTRO DE CIÊNCIAS AGRÁRIAS
CURSO DE ZOOTECNIA**

MEIRE LUIZA WIRTH

**AVALIAÇÃO DO USO DE SENSORES NA PREDIÇÃO DO
COMPORTAMENTO DE BOVINOS CONFINADOS**

Trabalho de Conclusão de Curso apresentado
como exigência para obtenção do Diploma de
Graduação em Zootecnia da Universidade Federal
de Santa Catarina.

Orientador: Prof. Dr. Márcio Cinachi Pereira

FLORIANÓPOLIS - SC

2023

Wirth, Meire Luiza

Avaliação do uso de sensores na predição do comportamento de bovinos confinados / Meire Luiza Wirth ; orientadora, Priscila Arrigucci Bernardes, orientador, Márcio Cinachi Pereira, 2023.
53 p.

Trabalho de Conclusão de Curso (graduação) - Universidade Federal de Santa Catarina, Centro de Ciências Agrárias, Graduação em Zootecnia, Florianópolis, 2023.

Inclui referências.

1. Zootecnia. 2. Zootecnia de precisão. 3. Monitoramento bovino. 4. Aprendizagem de máquina. 5. Acelerômetros triaxiais. I. Bernardes, Priscila Arrigucci. II. Pereira, Márcio Cinachi III. Universidade Federal de Santa Catarina. Graduação em Zootecnia. IV. Título.

Meire Luiza Wirth

AVALIAÇÃO DO USO DE SENSORES NA PREDIÇÃO DO COMPORTAMENTO DE BOVINOS CONFINADOS

Esta Monografia de Trabalho de Conclusão de Curso foi julgada aprovada e adequada para obtenção do grau de Zootecnista.

Florianópolis, 16 de junho de 2023.

Banca Examinadora:



Documento assinado digitalmente
Marcio Cinachi Pereira
Data: 04/07/2023 11:53:57-0300
CPF: ***.731.298-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof. Márcio Cinachi Pereira. Dr.
Orientador
Universidade Federal de Santa Catarina



Documento assinado digitalmente
PRISCILA ARRIGUCCI BERNARDES
Data: 03/07/2023 20:30:50-0300
CPF: ***.913.148-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof.^a Priscila Arrigucci Bernardes. Dr.^a
Central Queensland University



Documento assinado digitalmente
Milene Puntel Osmari
Data: 04/07/2023 11:53:44-0300
CPF: ***.886.630-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof.^a Milene Puntel Osmari. Dr.^a
Universidade Federal de Santa Catarina



Documento assinado digitalmente
Sandra Regina de Souza
Data: 04/07/2023 12:01:20-0300
CPF: ***.709.448-**
Verifique as assinaturas em <https://v.ufsc.br>

Prof.^a Sandra Regina S. T. Carvalho. Dr.^a
Universidade Federal de Santa Catarina

DEDICATÓRIA

Aos meus pais, Sr. Mauro e a Sra. Marlene Wirth, cujos dias de luta, trabalho duro, apoio e amor incondicional garantiram minha chegada até aqui.

A minha irmã, Cristiele Wirth, que é minha grande inspiração e meu maior exemplo.

A jóia rara de Florianópolis, Neusa Maria Locatelli, que com carinho abriu um espaço em sua casa e seu coração para minha morada.

Dedico.

AGRADECIMENTOS

Agradeço aos professores e servidores da Universidade Federal de Santa Catarina que com trabalho duro e dedicação apoiaram minha formação profissional em Zootecnia. Aos meus professores orientadores durante toda a jornada de graduação, em especial a Dr.^a Priscila Arrigucci Bernardes pela excelência, paciência e resiliência na orientação, permanecendo ao meu lado nos momentos mais adversos, mostrando-se um exemplo excepcional de profissional para ser seguido e disseminado, e ao Dr.^o Márcio Cinachi Pereira pelos “*insights*” e direcionamentos na fase final de minha jornada neste trabalho.

Agradeço a todos os membros e professores orientadores dos grupos de estudo GENPROR e NEAPET ao qual tive a grande oportunidade de participar, a jornada ao lado de vocês foi de grande valia para meu desenvolvimento pessoal e profissional.

Agradeço a Universidade Estadual Paulista pelos dados cedidos para a realização deste trabalho.

Um agradecimento especial à OPTA & ALLEGRO, cujos gestores abriram caminhos antes desconhecidos por mim e possibilitaram minha formação ainda mais completa pela experiência adquirida para o mercado de trabalho. Todos os desafios superados foram possíveis através de seu apoio e investimento, agradeço então por acreditarem em minhas habilidades.

Agradeço a todos que considero minha família, como a minha *best* “praga véia”, Keisy Anny de Souza Amorim, o presente em forma de amizade mais precioso, que tem tornado meus dias mais divertidos. Aos meus pais e irmãs pelo apoio incondicional e minha querida e amada Stephany Lopes, não existem palavras para agradecer a você pela grande parceira e pessoa incrível que és.

A todos que com paciência, apoio e dedicação me auxiliaram a concluir essa etapa, meus sinceros agradecimentos.

RESUMO

Com o desenvolvimento de diferentes tecnologias, tornou-se possível a obtenção de informações que colaboraram com o rápido desenvolvimento do setor agropecuário. Dentre as diferentes tecnologias disponíveis, os sensores individuais (acelerômetros) têm sido explorados no estudo de animais em confinamento, pois podem registrar informações de consumo alimentar e comportamento animal em tempo real. Dessa maneira, o presente trabalho avaliou se a habilidade de predição do comportamento de animais confinados utilizando informações de sensores triaxiais se modifica conforme varia o intervalo de tempo em que é feita a observação. Os dados experimentais foram obtidos de um estudo realizado na Universidade Estadual Paulista “Júlio de Mesquita Filho”, campus de Jaboticabal. Do total de 48 tourinhos anelados, 12 foram monitorados com sensores contendo acelerômetro que registravam informações de movimentos longitudinais, horizontais e verticais a cada 6 segundos. Para registro dos comportamentos observados, os animais foram filmados em diferentes momentos, totalizando 24 horas, com três comportamentos observados: visitas ao cocho, visitas ao bebedouro e outras atividades. Os intervalos de tempo considerados para a observação comportamental foram a cada 1, 5, 10 e 20 minutos. Com as informações obtidas pelos sensores e suas variáveis calculadas, foi realizado o treinamento do modelo para predição do comportamento animal por meio do modelo de “Random Forest. A habilidade de predição foi avaliada comparando o comportamento predito pelo modelo com o comportamento observado para os dados teste, utilizando as métricas obtidas pela matriz de confusão: acurácia, sensibilidade, especificidade, precisão, valor preditivo positivo (VPP) e valor preditivo negativo (VPN). O modelo apresentou adequada habilidade de predição do comportamento animal com sensibilidade e especificidade de moderada a alta para todos os intervalos de tempo, para os 3 comportamentos observados, porém quando os dados preditos foram comparados com os observados a cada 1 minuto a precisão dos modelos reduziram conforme o intervalo de tempo de observação se elevou. Dessa maneira, sugere-se o treinamento do modelo utilizando o intervalo de 1 minuto para obter melhor desempenho na predição, principalmente se o objetivo for detectar comportamentos menos frequentes.

Palavras chave: acelerômetros triaxiais, aprendizagem de máquina, classificação comportamental, “Random Forest”, zootecnia de precisão, zebuínos.

LISTA DE ABREVIATURAS E SIGLAS

AGV - Ácido Graxo Volátil
CMS - Consumo de Matéria Seca
EN - *Energy*
ENT - *Entropy*
FDN - Fibra Detergente Neutro
FN - Falso negativo
FP - Falso positivo
GI - *Gini impurity*
INC - *Inclination*
ML - Machine learning
MV - Movement variation
OOB - *Out-of-bag*
RF - *Random Forest*
SMA - Área de magnitude do sinal
SVM - Magnitude do vetor de sinal
VN - Verdadeiro negativo
VP - Verdadeiro positivo
VPN - Valor preditivo negativo
VPP - Valor preditivo positivo

SUMÁRIO

1. INTRODUÇÃO	1
2. OBJETIVOS	2
2.1 Objetivo geral	2
2.2 Objetivo específico	2
3. REVISÃO BIBLIOGRÁFICA	2
3.1 Comportamento ingestivo de bovinos de corte em confinamento	5
3.2 Consumo de água por bovinos de corte em confinamento.	7
3.3 Uso e tipos de dispositivos eletrônicos para avaliação comportamental de bovinos de corte	10
3.4 Aprendizado de máquina (machine learning)	12
3.5 Método Floresta Aleatória (Random Forest)	13
4. MATERIAL E MÉTODOS	14
4.1 Dados experimentais	14
4.2 Edição de dados e cálculo de variáveis	16
4.3 Predição do comportamento animal	19
4.4 Avaliação da predição do comportamento animal	21
5. RESULTADOS E DISCUSSÃO	23
5.1 Frequência comportamental	23
5.2 Acurácia	26
5.3 Kappa	28
5.4 Sensibilidade	28
5.5 Especificidade	30
5.6 Valor Preditivo Positivo	31
5.7 Valor Preditivo Negativo	32
5.8 Comparação da precisão dos comportamentos preditos com base no intervalo de 1 minuto	32
6. CONCLUSÃO	36
7. REFERÊNCIAS BIBLIOGRÁFICAS	36

1. INTRODUÇÃO

O confinamento de bovinos de corte é uma prática de gestão que busca explorar a capacidade produtiva do animal com o uso de tecnologias e rigorosos controles, com objetivo de obter animais com elevado desempenho em menor tempo, possibilitando, dentre uma diversidade de fatores, maior rentabilidade ao final do processo produtivo. Essa prática torna-se interessante principalmente pelo fato de que a criação de bovinos de corte em condições de pastejo torna-se um desafio para a produção animal, pois a produtividade e qualidade das forrageiras podem sofrer com a variação sazonal ao longo do ano devido às condições edafoclimáticas, prejudicando o desempenho animal, o que pode levar ao aumento da idade e tempo de abate e, conseqüentemente, afetar a produtividade no sistema de criação (SANTOS *et al.*, 2020).

Dessa maneira, no Brasil, a prática do confinamento, dentre os mais diversos motivos relacionados a técnicas de gestão, tem também como objetivo a engorda de animais durante a sazonalidade forrageira, que se caracteriza como um período de baixa qualidade e oferta de forragens. Neste contexto, a realização de estudos sobre o comportamento animal auxilia no entendimento de suas variações, permitindo aplicar os resultados para atingir maior precisão na gestão do rebanho, obtendo melhores índices econômicos, zootécnicos e reduzido impacto ambiental (MIZUBUTI *et al.*, 2013).

Aliado à busca pela precisão na gestão dos rebanhos está o registro semiautomático, automático ou manual (observação visual) de dados comportamentais. O uso de sensores automáticos de predição comportamental, descritos como ferramentas tecnológicas capazes de identificar movimentos, permite a exploração da complexidade dos sistemas e traz vantagens competitivas, uma vez que auxilia com registros em tempo real, enquanto a observação visual apresenta limitações referentes aos erros associados ao observador, obstáculos físicos e climáticos e efeito de proximidade sobre os animais (VALENTE *et al.*, 2013).

Dentre as ferramentas disponíveis no mercado atualmente, o cocho eletrônico e os sensores individuais têm sido explorados para o estudo comportamental, pois fornecem informações que podem representar comportamentos dos animais e, quando interpretadas, permitem proporcionar melhorias no manejo e no

desempenho animal (BREW *et al.*, 2011; BAILEY *et al.*, 2018; KOENING *et al.*, 2020).

Os sensores contendo acelerômetros fixados em colares foram desenvolvidos com objetivo de auxiliar no controle do rebanho por meio da avaliação comportamental dos animais, seja para finalidade reprodutiva, de sanidade ou nutricional (GONZÁLEZ *et al.*, 2015; SHAHRIAR *et al.*, 2016; WILLIAMS *et al.*, 2017; BENAÏSSA *et al.*, 2019; HAMILTON *et al.*, 2019; WERNER *et al.*, 2019; TOBIN *et al.*, 2020; PAVLOVIC *et al.*, 2021; TRAN *et al.*, 2021). Os sensores acelerômetros triaxiais realizam a identificação da aceleração de três direções diferentes, permitindo detectar os diferentes tipos de movimentos realizados pelos animais. Estes valores auxiliam na definição se os mesmos estão em atividade, se alimentando ou em estado de repouso. Todavia, ainda é necessário avaliar a eficiência da interpretação dos dados gerados por meio de sensores em diferentes intervalos de tempo.

2. OBJETIVOS

2.1 Objetivo geral

Verificar a precisão e o desempenho de um modelo de predição comportamental de bovinos de corte em confinamento, utilizando informações de sensores acelerômetros em diferentes intervalos de tempo.

2.2 Objetivo específico

- Avaliar se a habilidade de predição comportamental, através do uso de informações de sensores acelerômetros e o modelo de treinamento de máquina “Random Forest”, se modifica conforme a variação do intervalo temporal das observações registradas.

3. REVISÃO BIBLIOGRÁFICA

O Brasil é um dos principais produtores e exportadores de carne bovina do mundo. Em 2020 o volume de exportações aumentou 8% passando de 2,49 milhões

de toneladas em 2019 para 2,69 milhões de toneladas em 2020 (ABIEC, 2021). Em 2021, registrando um rebanho de 196,47 milhões de cabeças, a pecuária brasileira abateu 39,14 milhões de bovinos, sendo 15,4% originário de confinamentos. Desse montante, 74,49% teve como destino o mercado interno, enquanto 25,51% foi exportado (ABIEC, 2022). Foram 42,31 milhões de cabeças abatidas em 2022, um crescimento de 5,18% em relação ao ano anterior, sendo 18% deste montante representado por animais criados em confinamento (ABIEC, 2023).

Reconhecendo o papel que o Brasil possui frente a cadeia produtiva de carne bovina, o estudo do comportamento animal assume papel importante dentro da produção animal, pois através dele é possível desenvolver técnicas de manejo, alimentação e adequação nas instalações, buscando precisão e qualidade que atendam às exigências do consumidor. Desta forma, a etologia pode mostrar o caminho para a racionalização da criação animal, principalmente em sistemas intensivos de produção (ABRAHAMSSON, 1996).

Concisamente, o comportamento e o bem-estar animal devem ser considerados como uma demanda para qualquer sistema criatório que deseja ser ética e socialmente aceitável, pois o mercado deseja produtos com qualidade, provindos de animais criados, tratados e abatidos em sistemas que promovam o bem-estar e que sejam sustentáveis e ambientalmente corretos (MOGAMI, 2009). Desta maneira, aliado a busca por produtos de qualidade e automatização de sistemas está a utilização de tecnologias robotizadas, principalmente em áreas que exigem elevado grau de precisão, confiabilidade e velocidade. Além disso, a visão computacional tem evoluído rapidamente, com a criação de ferramentas que permitem um elevado entendimento de informações (PAULA FILHO *et al.*, 2010).

Portanto, o registro automático, semiautomático ou manual (observação visual) de dados comportamentais dos bovinos eleva a capacidade de precisão na gestão dos rebanhos. O uso de sensores automáticos de predição comportamental permite a exploração da complexidade dos sistemas e traz vantagens competitivas, uma vez que auxilia com registros em tempo real, enquanto a observação visual apresenta limitações referentes aos erros associados ao observador, obstáculos físicos e climáticos e efeito de proximidade sobre os animais (VALENTE *et al.*, 2013).

Assim, estes sensores automáticos individuais que contém acelerômetros fixados em sua estrutura são alternativas eletrônicas capazes de capturar a

aceleração e angularidade de movimentos, ferramenta que pode ser considerada substituta da observação visual da realização das principais atividades comportamentais (CASANOVA, 2020), foram desenvolvidos com intuito de auxiliar no controle do rebanho por meio da avaliação comportamental, fornecendo informações que, quando corretamente interpretadas, podem proporcionar melhorias no manejo e no desempenho animal (BREW *et al.*, 2011; KOENING *et al.*, 2020).

As coleiras eletrônicas permitem detectar os diferentes tipos de movimentos realizados pelos animais, podendo definir se os mesmos estão em atividade, se alimentando ou em estado de repouso. Todavia, a eficiência da interpretação dos dados gerados através de sensores em diferentes intervalos de tempo é um desafio que deve ser avaliado. Algumas dessas coleiras são compostas por sensores de alta performance e sensibilidade, detectando qualquer movimento do animal durante 24 horas ininterruptas, sendo estas informações armazenadas em uma memória interna na qual são transferidas para um servidor no momento em que o animal passa pela antena de captação de dados (SANTOS, 2019). Outras fornecem as informações em tempo real utilizando sistema wireless e armazenando estes registros em servidores (ROMANZINI *et al.*, 2022).

Aliada a esta tecnologia, utiliza-se um sistema de aprendizado de máquina (*machine learning*), onde o objetivo principal é prover ao computador as capacidades de percepção do sistema visual humano em relação ao ambiente. A visão computacional tem evoluído rapidamente, produzindo ferramentas que permitem o entendimento das informações visuais, especialmente em cenas com estruturas bem definidas (PAULA FILHO *et al.*, 2010).

De forma geral, durante as avaliações comportamentais dos bovinos, três atividades diárias são consideradas: alimentação, ruminação e ócio. De acordo com Mizubuti *et al.* (2013), os animais confinados respondem de maneiras diferentes, onde a duração e a distribuição de seu comportamento podem ser afetadas pelas características da dieta, manejo, condições climáticas e interação com outros animais do grupo.

A compreensão destes componentes que abrangem o comportamento animal depende da metodologia de avaliação. Existem metodologias diretas, através da avaliação visual e as indiretas, por meio de tecnologias (SANTOS, 2019). No método de avaliação visual, o registro das atividades comportamentais é realizado por

peessoas treinadas em intervalos de tempos determinados (SANTOS, 2019). Dentre os componentes utilizados no estudo do comportamento animal, a escolha do intervalo de tempo entre as observações é um fator importante, uma vez que a observação contínua dos animais é um processo que demanda muita mão-de-obra, tornando-se impraticável quando se deseja observar um número elevado de animais (SILVA *et al.*, 2005a).

Visando obter resultados satisfatórios, a escolha da escala do intervalo para discretizar as séries temporais deve ser um compromisso entre o poder de detectar mudanças na ocorrência das atividades e a precisão, sem, no entanto, incorrer em redundância. Portanto, faz-se necessário estabelecer a metodologia adequada a ser utilizada para obter dados de alta confiabilidade (SILVA *et al.*, 2005a). Fischer *et al.* (2000) verificaram que a duração das refeições é mais variável que a duração dos períodos de ruminação e ócio, indicando que a discretização das séries temporais feita em escala superior a 5 minutos de intervalo resulta em uma maior perda de observações, o que diminuiria a precisão quanto ao número de refeições diárias.

3.1 Comportamento ingestivo de bovinos de corte em confinamento

O estudo do comportamento ingestivo dos bovinos é uma ferramenta de grande importância, pois através dela que se torna possível ajustar o manejo alimentar e as dietas para a obtenção de melhor desempenho produtivo (MENDONÇA *et al.*, 2004; CARDOSO *et al.*, 2006). Além disso, os estudos e conhecimento acurado sobre os hábitos comportamentais dos animais podem ser úteis nos sistemas de reprodução, pois qualquer mudança no padrão comportamental pode ser entendida como indicadores que afetam o manejo, alimentação ou problemas de saúde (ORTÊNCIO *et al.*, 2020).

De acordo com Bailey *et al.* (2018), para estudar o comportamento ingestivo de bovinos de corte, geralmente é desejável que as observações sejam feitas durante as 24 horas do dia. Dessa maneira, o uso de coleiras com sistema de posicionamento global (GPS) e acelerômetros se mostram promissores no monitoramento aliado à precisão e economia, fornecendo informações sobre a distribuição do comportamento durante o período estipulado para observação.

Alguns estudos apontaram que animais alojados individualmente alteram significativamente seu desempenho e comportamento ingestivo quando comparados

a outros ambientes de produção e condições de alojamento (GUIROY *et al.*, 2001; BEATTY *et al.*, 2006). Também, foi verificado que os bovinos respondem diferentemente às características dos alimentos, como composição bromatológica das pastagens, que influenciam fatores mecânicos como a mastigação, deglutição, regurgitação, motilidade gástrica e intestinal e defecação; fatores secretórios das glândulas digestivas; produção e secreção de enzimas e substâncias das mucosas gástricas; fatores microbianos que abrangem as atividades secretoras dos microorganismos (bactérias, protozoários, fungos e leveduras) presentes no estômago e intestino dos animais ruminantes (FERREIRA *et al.*, 2013); e também sobre as proporções de ingredientes e tipos de dieta, influenciando no comportamento alimentar, na fertilidade e no desempenho produtivo dos bovinos em confinamento (VAN SOEST *et al.*, 1991; ARGENTA *et al.*, 2013; MIZUBUTI *et al.*, 2013; ARGENTA *et al.*, 2019).

O manejo, por sua vez, também tem influência sobre o comportamento natural dos bovinos, uma vez que o comportamento de consumo se eleva nos horários de fornecimento de alimento no cocho (SEGABINAZZI *et al.*, 2014), ou em momentos em que o manejador faz visitas em horários alternativos para realizar as checagens diárias e revolvimento do material restante, provocando um estímulo de alimentação e aumento das visitas ao cocho dos animais.

Em seu experimento, Mizubuti *et al.* (2013) compararam o comportamento de bovinos em confinamento alimentados com três diferentes híbridos de milho. Verificaram que ocorreram diferenças entre os tratamentos para tempo de mastigação e para número de bolos ruminais. Quanto maior for a quantidade de fibra detergente neutro (FDN), e/ou o maior tamanho de partícula, maior será o tempo despendido em atividades de mastigação (alimentação e ruminação) e menor o tempo de ócio, o que pode influenciar a capacidade de ingestão de alimentos (VAN SOEST, 1991; CARVALHO *et al.*, 2014; ARGENTA *et al.*, 2019; ORTÊNCIO *et al.*, 2020). Estudar esses parâmetros de tempo de alimentação, ruminação e ócio nos diferentes sistemas de criação e fases de vida nos permite criar respostas em manejo e bem-estar para melhorar o rendimento dos animais.

O tempo gasto em ruminação é mais prolongado à noite, mas também é influenciado pelo alimento (ARGENTA *et al.*, 2013). No entanto, existem diferenças entre indivíduos quanto à duração e à repartição das atividades de ingestão e

ruminação, que parecem estar relacionadas ao apetite dos animais, diferenças anatômicas e ao suprimento das exigências energéticas ou enchimento ruminal (SOUZA *et al.*, 2007). Welch (1982) observou que os bovinos que ruminam por um período maior durante um intervalo de tempo tendem a ser mais produtivos, em função da maior ingestão da fração fibrosa na dieta, disponibilizando maior quantidade de substrato em menor tempo para os microrganismos do rúmen e conseqüentemente, ocorrendo maior produção de ácidos graxos voláteis (AGV), principais fontes de energia para os ruminantes.

Referente ao número de refeições ao dia, Freitas *et al.* (2010) encontraram um valor médio de 10,48 refeições ao dia, enquanto que Argenta *et al.* (2013) identificaram uma média de 7,72 refeições ao dia e Segabinazzi *et al.* (2014) relataram 4,91 visitas ao comedouro, com duração média de 36,16 minutos cada. Esta diferença pode ser atribuída a características e composição da dieta, disponibilidade e facilidade de obtenção de alimento, comportamento social, categoria animal, localização dos comedouros e bebedouros, clima e condições ambientais (ARGENTA *et al.*, 2013). Bürger *et al.* (2000), por sua vez, verificaram que bovinos mantidos em pastagens se caracterizam por períodos longos de alimentação, variando de quatro a doze horas por dia, enquanto que animais confinados passam de uma a seis horas, para dietas com baixo teor de energia.

O ócio, por sua vez, representa o tempo em que o animal não está ingerindo alimento e nem ruminando, podendo estar em pé ou deitado, mas geralmente os animais permanecem maior tempo em ócio deitados no período noturno (ARGENTA *et al.*, 2013). Quando se avalia o tempo de ócio de um animal, essa variável se torna importante em animais de produção, ou seja, o animal que está em ócio terá seus gastos em energia reduzidos (ARGENTA *et al.*, 2013).

3.2 Consumo de água por bovinos de corte em confinamento.

Poucos estudos utilizando sensores individuais têm sido realizados para a medição da ingestão ou frequência de visitas ao bebedouro de bovinos de corte. Conforme Williams *et al.* (2017), o comportamento de consumo de água foi relatado em estudos com ambientes controlados, porém, devido à disparidade da frequência dos comportamentos observados, os autores sugeriram mais estudos para adaptar melhor os modelos de aprendizado de máquina de forma a obter melhor

desempenho na predição e classificação de comportamentos de baixa frequência, uma vez que o desempenho satisfatório dos modelos de predição está ligado a um treinamento de máquina eficiente.

Todavia, existem sensores eficientes para quantificar consumo de água em confinamento, como as integrações com transponders e bebedouros eletrônicos com balança, como o usado por Sousa (2022). Porém esses sensores não são capazes de prever outros comportamentos, como ruminância e ócio, por exemplo. Essa é a vantagem dos sensores individuais como o acelerômetro, objeto do presente estudo.

Considerando a água como um recurso natural finito, o crescente consumo global de carne e a intensificação dos sistemas de produção animal pressionarão ainda mais os recursos globais de água doce nas próximas décadas, o que exige estudos que meçam com eficiência o uso da água nos diversos sistemas de agricultura e produção animal. Os incidentes relatados de esgotamento das águas subterrâneas, rios secando e níveis crescentes de poluição são uma indicação da crescente escassez de água (MEKONNEN; HOEKSTRA, 2012).

Os produtos animais dos sistemas industriais geralmente consomem e poluem mais recursos hídricos subterrâneos e superficiais do que os resíduos provenientes de sistemas de pastoreio ou mistos (MEKONNEN; HOEKSTRA, 2012). Desta forma, como a produção e o consumo animal desempenham um papel importante no esgotamento e poluição dos escassos recursos de água doce do mundo, o estudo sobre consumo de água do gado de corte nos auxilia a entender como podemos usar de forma sustentável e eficiente este recurso.

Mekonnen e Hoekstra (2012) realizaram um estudo referente à pegada hídrica de produtos de origem animal. Classificaram o consumo de água em três: a pegada hídrica azul refere-se ao consumo de recursos hídricos azuis (superficiais e subterrâneos) ao longo da cadeia de abastecimento de um produto; a pegada hídrica verde refere-se ao consumo de recursos hídricos verdes (água da chuva na medida em que não se transforma em escoamento); a pegada hídrica cinza refere-se à poluição e é definida como o volume de água doce necessário para assimilar a carga de poluentes dadas as concentrações naturais de fundo e os padrões de qualidade da água do ambiente. Desta forma, os autores apontam que a pegada hídrica de qualquer produto de origem animal é maior do que a de produtos agrícolas com valor nutricional equivalente.

A pegada hídrica média por caloria para carne bovina é 20 vezes maior do que para cereais e raízes amiláceas (MEKONNEN; HOEKSTRA, 2012). De acordo com os mesmos autores, no Brasil, 98,7% da água usada na pecuária é verde, 0,71% é água azul e 0,59% é água cinza. No mundo, 29% da pegada hídrica total do setor agrícola está relacionada a produtos de origem animal e um terço dela está relacionada ao gado de corte (MEKONNEN; HOEKSTRA, 2012).

Devido à maior dependência de alimentos concentrados nos sistemas de confinamento, a intensificação dos sistemas de produção animal resultará no aumento das pegadas hídricas azul e cinza por unidade de produto animal. A pressão sobre os recursos globais de água doce aumentará, portanto, devido ao aumento do consumo de carne e ao aumento da pegada hídrica azul e cinza por unidade de carne consumida (MEKONNEN; HOEKSTRA, 2012). Ammer *et al.* (2017) observaram que variações no teor de matéria seca da dieta, tipo de silagem e proporção de concentrado podem ter influência sobre o consumo de água de bovinos em confinamento.

Um estudo realizado por Palhares *et al.* (2021) considerou a pegada hídrica para as três principais fases da produção de carne bovina: bezerro, engorda e confinamento, com fornecimento de duas dietas distintas, uma convencional e outra com adição de coprodutos. Nesse estudo, bezerros do nascimento ao desmame consumiram 23 L/dia de água (pegada hídrica azul) e na fase de engorda o consumo de água azul variou de 20,4 a 29,7 L dia, dependendo do consumo alimentar e indicadores climáticos. Os animais no confinamento alimentados com dieta convencional tiveram uma média diária de ingestão de água de 19,7 L/dia em comparação com 23,1 L dia para animais alimentados com dieta + coproduto.

O autor acrescenta ainda que no ano de 2018 foram abatidos 5,58 milhões de cabeças de gado provenientes do confinamento e, considerando os valores médios das pegadas hídricas, a água consumida por esses animais quando alimentados com dietas de coprodutos apresentaria uma variação de 43,3 a 46,7 teralitros e para animais alimentados com dietas convencionais seria de 45,1 a 46,0 teralitros, complementando que o tipo de dieta poderia diminuir o consumo de água em 1,8 teralitros anualmente (PALHARES *et al.*,2021).

Brew *et al.* (2011) utilizando o sistema de alimentadores eletrônicos (GrowSafe™, GrowSafe Ltd, Airdrie, Alberta, Canadá) que usa identificação por

radiofrequência, verificaram que o consumo médio diário de animais em confinamento com peso entre 200 e 400 kg e ganhando a uma taxa de 1,41 kg/d, em um ambiente com temperatura dentro da zona térmica neutra (15 °C) durante todo o estudo, foi de 29,98 L \pm 8,56 L/cabeça/d. A ingestão de água correlacionou-se com o ganho médio diário e o consumo de ração, mas não com a eficiência alimentar. Todavia isto não significou que estes animais foram mais eficientes do que o gado que consumia menos água.

Os autores Polli *et al.* (1995) observaram o comportamento de ingestão de água de bovinos confinados em condições de clima subtropical (temperatura média 15,2°C, umidade relativa 75,0%), alimentados à vontade com duas fontes de volumosos (cana-de-açúcar ou silagem de milho, constituindo-se 70% da dieta total) e 30% de concentrado, por um período de 120 dias. Verificaram que, em média, os bovinos se dirigiram para os bebedouros e consumiram água quatro vezes durante as 24 horas do dia, sendo três diurnas e uma noturna.

3.3 Uso e tipos de dispositivos eletrônicos para avaliação comportamental de bovinos de corte

Para reduzir os riscos de ocorrência de problemas como o efeito da presença dos humanos sobre o comportamento natural dos animais durante as observações, pode-se utilizar ferramentas tecnológicas como os dispositivos de registro eletrônico, que tornam possível avaliar o comportamento dos bovinos ao longo do tempo, com alto nível de detalhamento e em diferentes condições de criação (ADAMCZYK *et al.*, 2013). A vantagem da utilização de sistemas computacionais e sensores de predição comportamental em relação ao sistema visual humano é a possibilidade de realizar medições exatas que não influenciem significativamente no comportamento animal e também anulam a subjetividade do observador humano (MOGAMI, 2009).

É importante considerar, porém, que qualquer dispositivo colocado no animal pode interferir em parte no seu comportamento natural, pelo qual é necessário que o animal seja habituado previamente ao uso do dispositivo para que se tenha uma melhor apreciação do comportamento natural. Em outros contextos, estes dispositivos também podem auxiliar no estudo dos fatores individuais, mas em situações que não se encontram frente à presença dos humanos, avaliando como os

fatores poderiam afetar, por exemplo, o comportamento de ingestão dos animais, como foi demonstrado no estudo de Alvarenga *et al.* (2016).

De acordo com Adamczyk *et al.* (2013), o comportamento do bovino pode ser estudado usando dispositivos e sensores, como o Sistema de Posicionamento Global (GPS) e o Sistema de Informação Geográfica (GIS) em espaços abertos (por exemplo, pastagens), ou usando sistemas de rastreamento e monitoramento (posicionamento x, y, z em 3D e espaço 2D) em celeiros. Todavia, uma das principais limitações para o uso desses sistemas em larga escala tem sido o custo de aquisição e instalação. Esta ferramenta pode servir para avaliar características comportamentais em bovinos de diferentes idades mantidos em diferentes condições, minimizando o efeito de interpretações antropomórficas do comportamento animal (ADAMCZYK *et al.*, 2013).

Ungar *et al.* (2005) justificaram o uso de sensores e coleiras GPS de monitoramento pela necessidade de quantificar as atividades ou movimentações de animais expostos a diferentes tratamentos, de uma forma que fosse possível relacionar atividades georreferenciadas com características específicas do local do habitat através de um sistema de informação geográfica. A integração de sensores de movimento ao longo do eixo esquerdo-direito e dados precisos de posição geográficas fornece o melhor método disponível até o momento para determinar a atividade animal (como pastoreio e ócio) e o uso de recursos em ambientes remotos.

Além disso, modelos preditivos com intervalo de correção de 5 minutos seriam melhores do que para os de 20 minutos, porque uma única atividade é mais provável para cada observação, obtendo uma taxa de erro de classificação de atividades em 12% a 14%. No entanto, o erro do GPS pode dificultar a separação entre descanso e pastejo com base na distância na escala de tempo mais curta (UNGAR *et al.*, 2005). Bailey *et al.* (2018) afirmam que quanto menor o tempo no registro de movimentos através de dispositivos eletrônicos GPS, maior é a acurácia na predição do movimento. Todavia, a calibração para registros em menor tempo resulta em menor vida útil da bateria, ocasionando a diminuição do período de registros.

Todavia, para o caso dos acelerômetros, Bailey *et al.* (2018) definiram que são sensores que registram os movimentos da cabeça do animal e que, posteriormente, podem ser combinados com velocidade entre os locais registrados para classificar os comportamentos do gado, como pastejar, andar e repouso. Os registros de

aceleração podem ser usados para medir remotamente a postura corporal e comportamentos. A postura para baixo, por exemplo, pode ser interpretada como pastejo. A aceleração dinâmica também é usada, tanto em sistemas de confinamento quanto de pastejo, para estimar mudanças nos padrões comportamentais ou problemas no bem-estar que podem indicar adoecimento ou baixo consumo de água e alimentos, ou até estimar o gasto de energia de um animal, neste caso mais eficientemente quando associado a monitoramento da frequência cardíaca (BAILEY *et al.*, 2018).

Um fator importante no uso de acelerômetros para determinação comportamental é o posicionamento do dispositivo no corpo do animal e a calibração dos dados do sensor para comportamentos observados (UNGAR *et al.*, 2005). Quando os acelerômetros são montados em coleiras, pode haver diferenças substanciais entre os animais e observações visuais são necessárias para desenvolver relações entre sinais de aceleração e comportamento (BAILEY *et al.*, 2018).

3.4 Aprendizado de máquina (machine learning)

O aprendizado de máquina (*machine learning* - ML) é uma subárea da inteligência artificial (IA) que se concentra no desenvolvimento de algoritmos e técnicas que permitem aos computadores aprender através do reconhecimento de padrões, permitindo realizar previsões ou tomar decisões com base em dados fornecidos, sem serem estritamente programadas (LIAKOS *et al.*, 2018). Dentre os métodos e algoritmos aplicáveis existentes, o processo de aprendizado de máquina envolve, de forma geral, a divisão dos dados em etapas para treinamento, o qual contém as variáveis de saída, e teste, no qual o algoritmo irá aplicar os padrões aprendidos para realizar predição ou classificação de dados (MAHESH, 2020).

A aplicação do conjunto de dados de teste, os quais não foram usados no treinamento, permite avaliar o desempenho do modelo em dados desconhecidos e verificar sua precisão na aplicação dos padrões aprendidos durante o treinamento. Com os resultados, uma vez satisfatórios, podem ser utilizados para auxiliar na tomada de decisões no campo de estudo ou coleta de dados, além de reduzir custos de produção e aumentar a eficiência do sistema (NEETHIRAJAN, 2020).

A produção pecuária tem sido influenciada por uma fase de digitalização impulsionada pelas demandas do mercado. Visto que um dos destaques da IA é sua aplicação em um ambiente de geração de grande quantidade de dados para apoiar processos de gerenciamento, o progresso do aprendizado de máquina aplicado à pecuária em curto prazo é promissor.

Uma vez aplicada, o monitoramento da atividade animal em sistemas de produção é uma ferramenta importante para detectar e isolar problemas de produtividade causados por doenças ou quaisquer outros fatores (WATANABE *et al.*, 2021), pois qualquer perturbador na produtividade tem menos impacto quando detectado precocemente, já que a disseminação para outros animais pode causar sérios danos e problemas econômicos aos produtores (MEGETO *et al.*, 2020). Como ferramenta para o monitoramento contínuo dos animais, pode-se aplicar o uso de acelerômetros para classificar e prever o comportamento animal (WATANABE *et al.*, 2021).

Uma alternativa para ajustar amplos e complexos conjuntos de dados é a utilização de métodos de aprendizagem de máquina, que possuem habilidades para mineração de dados e desenvolvimento de ferramentas preditivas (SHAHINFAR *et al.*, 2014), com a finalidade de atingir informações úteis (CAVALCANTI *et al.*, 2015). O aprendizado de máquina (*machine learning*) realiza o treinamento do computador para determinar uma resposta utilizando parte de um todo (os dados de treinamento) com base no cenário criado pela interseção das variáveis de entrada (CAVALCANTI *et al.*, 2015). Atualmente, existem diferentes métodos de aprendizagem de máquina e análises multivariadas que podem ser utilizados na classificação e predição de ocorrências de um determinado evento, a exemplo do “Random Forest”.

3.5 Método Floresta Aleatória (Random Forest)

O método “Random Forest” foi proposto por Breiman (2001) como uma extensão de seus trabalhos anteriores, tendo como base o método “bagging” para gerar conjuntos de classificadores. Esse método é utilizado para respostas binárias ou classificatórias e consiste em um algoritmo de aprendizado de máquina amplamente utilizado para tarefas de classificação e regressão, combinando várias árvores de decisão individuais para criar um modelo preditivo mais robusto e preciso (BREIMAN, 2001).

A proposta do “Random Forest” inicia-se com a seleção de uma amostra aleatória dos dados para treinamento e teste, pois o algoritmo fornece funções para treinar e fazer previsões através dos dados. Em seguida, o modelo seleciona um subconjunto aleatório de variáveis para criar árvores de decisão (ou probabilidades) independentes, que são desenvolvidas a partir de uma variável com menor critério “Gini impurity” (GI) escolhido para determinar o nó (folhas) de divisão (BREIMAN, 2001). Este procedimento é repetido para cada formação de um novo nó, até que uma árvore seja formada. As árvores crescem até atingir um critério de parada, como o número máximo de nós ou de árvores.

Cada árvore é treinada usando uma amostra aleatória dos dados de treinamento, que é selecionada através do método de substituição (ou bootstrap), proporcionando a cada árvore uma visão ligeiramente diferente do conjunto de dados, ajudando a reduzir a correlação entre as árvores e a aumentar a diversidade do modelo (BREIMAN, 2001). Ao final da construção e treinamento das árvores de decisão, o “Random Forest” usa o método de "votação", onde cada árvore tem um peso sobre uma classe e a com maior número de votos é selecionada como a previsão final (BREIMAN, 2001). Por fim, o desempenho do modelo pode ser avaliado por métricas, utilizando os dados que não fazem parte da amostra de “bootstrap” para fazer a predição, estabelecendo a taxa de erro denominada “out-of-bag” (OOB) e as medidas de importância das variáveis (BREIMAN, 2001).

4. MATERIAL E MÉTODOS

4.1 Dados experimentais

Os dados experimentais foram obtidos de um estudo de confinamento realizado por um período de 55 dias sob aprovação da Comissão de Ética no Uso de Animais da Universidade Estadual Paulista “Júlio de Mesquita Filho” Campus de Jaboticabal (protocolo nº 007979/18), no setor de Forragicultura e Pastagens da instituição. O clima da região é subtropical úmido, com inverno seco e verão chuvoso, com precipitação média de 628,8 mm, equivalente a 44,2% do total anual de chuvas. A umidade relativa média anual foi de 71,2%, com os meses mais úmidos sendo janeiro, fevereiro e março. A temperatura média anual registrada no período foi de 22,3°C, com média máxima de 29,1°C e média mínima de 16,9°C.

O estudo foi realizado no ano de 2020, em que os animais utilizados foram alojados em baias coletivas de 48 m² (6 x 8 m), com cobertura, cocho e bebedouro (Figura 1), com quatro animais em cada baia, totalizando 48 animais distribuídos em 12 baias. A dieta oferecida foi igual para todos os animais e formulada utilizando coprodutos agroindustriais nas seguintes proporções: 16% de casca de amendoim, 42% de casca de soja, 23% de gérmen de milho desengordurado, 15,5% de farelo de algodão, 0,5% de ureia e 3% concentrado comercial.



Figura 1. Bovinos alojados em baias coletivas na estação experimental do setor de Forragicultura e Pastagens da UNESP.

Do total de 48 tourinhos anelados, 12 foram monitorados com sensores contendo acelerômetro. Destes animais, seis tiveram os sensores fixados na região mandibular de cabrestos e seis tiveram sensores fixados em colares (Figura 2 e 3).

Os sensores utilizados continham acelerômetros triaxiais (Ovi-bovi®) (Minsk, Belarus), que utilizam um sistema microeletromecânico (MEMS) (modelo LIS2DE12; ST Microelectronics ® (Plan-les-Ouates, Suíça)), pesando 80 g, com dimensões de 105 mm × 60 mm × 22 mm, que registravam informações de movimentos horizontais (X — lado a lado), movimentos longitudinais (Y — da frente para trás) e verticais (Z

— para cima e para baixo) a cada 6 segundos. Os dados foram coletados por meio de um sistema sem fio e armazenados no servidor da empresa. Posteriormente, esses dados foram acessados e mantidos para o desenvolvimento do presente trabalho.



Figura 2 e 3. Bovino com cabresto (2) e colar (3) equipado com acelerômetro.

Os animais foram adaptados ao uso dos colares e cabrestos previamente à coleta de dados e posteriormente foram filmados em quatro diferentes momentos do período experimental (entre 06:00 até 18:00), durante 6 dias do mês de junho, 2 dias de julho e 1 dia de agosto do ano de 2020, por períodos contínuos de 6 horas, totalizando 24 horas de registro diurno para cada animal, uma vez que os bovinos são animais diurnos com frequência de atividades alimentares maiores durante o dia, podendo variar em caso de altas temperaturas (SEGABINAZZI *et al.*, 2014). Os vídeos dessas filmagens foram utilizados para registrar os comportamentos observados, considerando as seguintes atividades: visita ao cocho, visita ao bebedouro e outras atividades (deitado, ruminando, parado). Diferentes intervalos de tempo para a observação das atividades foram considerados, onde foi observado o comportamento a cada 1 minuto, 5 minutos, 10 minutos e 20 minutos, com precisão de minuto e segundo para cada observação.

4.2 Edição de dados e cálculo de variáveis

O “Random Forest” neste presente trabalho foi selecionado para cumprir a proposta de classificação de dados de acordo com Breiman (2001), onde ao utilizar as informações de comportamento observado dos animais seria possível prever

corretamente seu comportamento com base nas variáveis de aceleração dos eixos x, y e z registradas pelos *tags* e as variáveis preditoras calculadas (Tabela 1).

Todos os dados do acelerômetro foram editados usando o programa computacional R (versão 4.3.0 [2023-04-21]) (R Core Team, 2023). Os dados dos acelerômetros foram acessados pelo servidor do provedor dos sensores Ovi-Bovi® (Minsk, Belarus), os quais consistiam na identificação do sensor, informações de hora e data e as variáveis dos eixos do movimento, x, y e z (transformadas em unidade de gravidade $g=ms^{-2}$, por meio da relação, 64 unidades de leitura do dispositivo correspondem a 1 g). Além das variáveis fornecidas pelos acelerômetros, foram calculadas algumas variáveis para o presente trabalho, as quais foram utilizadas em condições experimentais similares a Alvarenga *et al.* (2016), sendo: área de magnitude do sinal (da sigla em inglês *SMA* - distingue entre períodos de atividade ou descanso); magnitude do vetor de sinal (da sigla em inglês *SVM* - indica o grau de intensidade do movimento); variação de movimento (*MV - Movement Variation*); energia (*En - Energy*); Entropia (*Ent - Entropy*); “Pitch”; “Roll” e Inclinação (*Inc - Inclination*); sendo as últimas três variáveis medidas em graus (Tabela 1).

As variáveis calculadas passaram por um controle de qualidade, em que foram desconsideradas informações sequenciais com intervalos maiores de 60 segundos. Para a formação do arquivo de dados de observações a cada 1 minuto iniciou-se as observações em determinado minuto e segundo e, para este momento, foi anotado o comportamento. Como as informações do acelerômetro eram realizadas a cada 6 segundos, o arquivo de dados continha 10 diferentes informações de acelerômetro (x, y e z) dentro de um minuto. Dessa maneira, o comportamento observado no minuto e segundo inicial foi repetido como resposta para os 10 próximos momentos. Quando o próximo minuto se iniciava, anotava-se o novo comportamento, o qual se repetiria como resposta para todos os dados obtidos pelo acelerômetro dentro daquele minuto. Assim, seguiu-se até completar todo o período observado. Para a formação do arquivo de dados de observações a cada 5 minutos, o comportamento observado no minuto e segundo inicial foi repetido como resposta para os próximos 50 momentos, até completar 5 minutos. Então anotava-se o novo comportamento, o qual se repetiria como resposta para todos os dados obtidos pelo acelerômetro dentro daqueles 5 minutos, o mesmo procedimento foi repetido para os 5 minutos seguintes até completar o período observado. Esse

método foi aplicado também para a formação dos arquivos de dados de 10 e 20 minutos, permitindo que ao final da formação dos arquivos, todos os arquivos de dados apresentassem o mesmo número de linhas.

Tabela 1. Variáveis preditoras calculadas a partir das variáveis de aceleração dos eixos x, y e z.

Preditores	Equação
<i>SMA</i>	$ X_i + Y_i + Z_i $
<i>SVM</i>	$\sqrt{X_i^2 + Y_i^2 + Z_i^2}$
<i>Movement Variat</i>	$ X_{i+1} - X_i + Y_{i+1} - Y_i + Z_{i+1} - Z_i $
<i>Energy</i>	$(X_i^2 + Y_i^2 + Z_i^2)^2$
<i>Entropy</i>	$(1 + (X_i + Y_i + Z_i))^2 \times \ln(1 + (X_i + Y_i + Z_i))$
<i>Pitch</i> (graus)	$\tan^{-1} \left(\frac{-X_i}{\sqrt{Y_i^2 + Z_i^2}} \right) \times \frac{180}{\pi}$
<i>Roll</i> (graus)	$\text{atan 2}(Y_i, Z_i) \times \frac{180}{\pi}$
<i>Inclination</i> (graus)	$\tan^{-1} \left(\frac{\sqrt{Y_i^2 + Z_i^2}}{Z_i} \right) \times \frac{180}{\pi}$

SMA: área de magnitude do sinal; *SVM*: magnitude do vetor de sinal; *Movement Variation*: Variação do movimento; *Energy*: Energia; *Entropy*: Entropia; *Inclination*: Inclinação.

Em que: *i* corresponde a leitura num dado tempo para os eixos X, Y e Z; *i+1* corresponde a leitura posterior a atual (*i*); *ln* corresponde ao logaritmo neperiano; *tan* corresponde à tangente; *atan* corresponde ao arco tangente e π corresponde à constante 3,14159265359. Todos os algoritmos utilizaram no processo dados do acelerômetro (x, y e z), as variáveis calculadas e a hora do dia como preditores e os comportamentos registrados dos animais foram considerados como variável de resposta.

4.3 Predição do comportamento animal

Após o controle de qualidade, o banco de dados utilizado foi dividido entre dados de treinamento e predição, sendo utilizada a metodologia de validação cruzada, no qual propõe a divisão dos dados em 4 grupos de validação (para predição dos comportamentos) de forma aleatória. A formação desses grupos permitiu a montagem de 4 novos grupos para treinamento do modelo, onde cada um desses grupos recebeu dados de três dos grupos de validação (Figura 4).

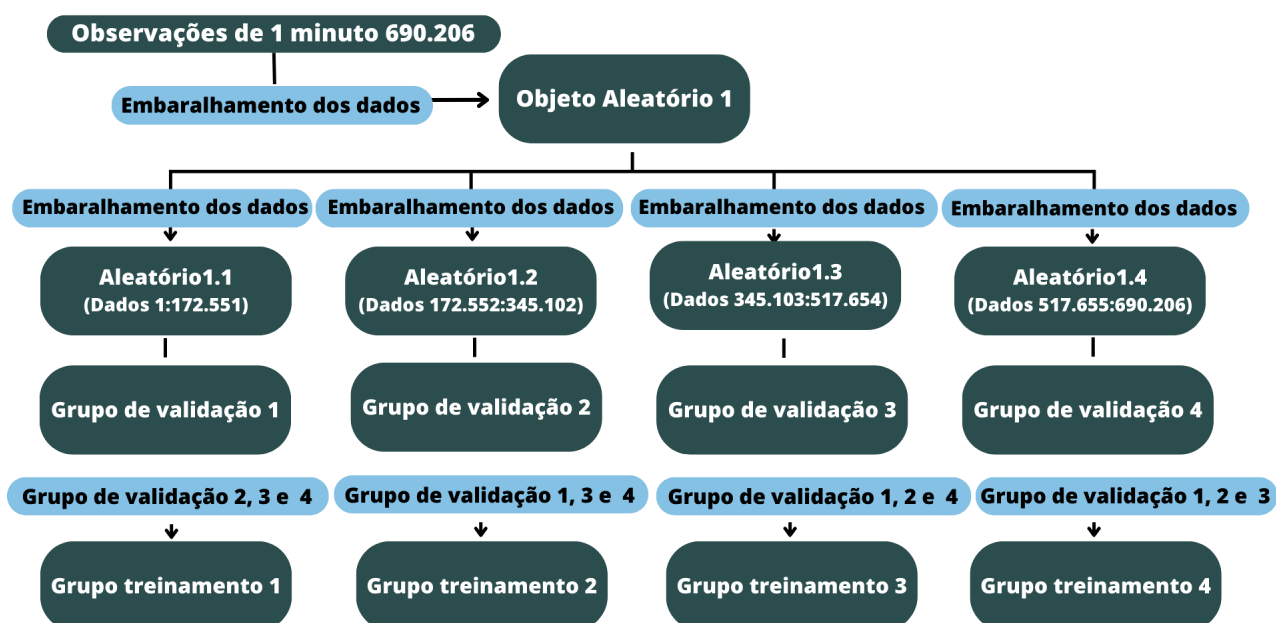


Figura 4. Validação cruzada e formação dos grupos de treinamento. Fonte: a autora.

No banco de dados treinamento a avaliação das melhores combinações de parâmetros foi realizada, com a finalidade de estabelecer a configuração ideal para a obtenção do melhor desempenho do modelo de aprendizagem “Random Forest”. Assim, foi utilizado número de árvores na floresta (“ntree”), considerando 1000 árvores e seis marcadores presentes em cada conjunto de variáveis usados para formar a árvore (“mtry”).

Após estabelecida a melhor configuração para o modelo, os dados de treinamento foram submetidos ao método de subamostragem (*under-sampling*) avaliado por Watanabe *et al.* (2021). Essa técnica de reamostragem *under-sampling* é usada para rebalancear o número de observações a fim de facilitar o efeito da distribuição de classes assimétricas no processo de aprendizado de um algoritmo de

predição, sendo mais versátil, pois é independente do algoritmo de classificação (LÓPEZ, *et al.*, 2013).

A escolha do método foi fundamentada no fato de que classes de comportamento menos frequentes podem levar a formação de um conjunto de dados com uma ou algumas das classes comportamentais avaliadas com um número maior de observações, apresentando-se como um grande gargalo no desempenho dos algoritmos de classificação (ZHENG *et al.*, 2015), pois aumenta-se a dificuldade de detecção devido sua infrequência e casualidade, o que resulta em classificação incorreta dessas classes (HAIXIANG, *et al.*, 2017). A exemplo dos dados utilizados, o método de subamostragem permitiu eliminar o dano causado pela distribuição distorcida dos dados, descartando amostras aleatoriamente para que todas as classes tivessem a mesma frequência que a classe minoritária. O método é aplicável através da função “downSample” do pacote caret, no programa computacional R (KUHN, 2008).

Esta técnica de reamostragem dos dados de treinamento dos modelos para melhor desempenho em classificação dos comportamentos estudados é especialmente importante para atividades menos frequentes, como é o caso da frequência de consumo de água, pois dados desbalanceados podem prejudicar a capacidade preditiva do método (WATANABE *et al.*, 2021).

Consequente, o treinamento foi realizado utilizando os valores de X, Y, Z, SMA, SVM, MV, En, Ent, Pitch, Roll, Inc, hora do dia como sendo os preditores e como resposta o comportamento observado a cada 1 minuto (comendo, bebendo e outras atividades). Após o treinamento, o modelo foi utilizado nos dados de validação onde foram inseridos apenas as informações dos preditores X, Y, Z, SMA, SVM, MV, En, Ent, Pitch, Roll, Inc e hora do dia para obter a predição do comportamento animal (comendo, bebendo e outras atividades).

Aplicou-se essa mesma sequência para a predição do comportamento utilizando as observações de a cada 5, 10 e 20 minutos. Os resultados das predições do comportamento animal das quatro análises foram comparados com o comportamento observado para aqueles dados. Todas as análises foram desenvolvidas no programa computacional R (versão 4.3.0 [2023-04-21]) (R CORE TEAM, 2023).

4.4 Avaliação da predição do comportamento animal

A habilidade de predição foi avaliada por meio da acurácia, a qual mede a frequência com que o classificador faz a previsão correta e calcula a proporção de casos classificados corretamente para o número total de casos (ALPAYDIN, 2014). Também foi calculada a matriz de confusão, em que é apresentado o número de classificações corretas em relação às classificações preditas para cada comportamento, classificando as predições em quatro categorias: Verdadeiro Positivo (VP) — número de instâncias em que o comportamento animal de interesse foi classificado corretamente, Verdadeiro Negativo (VN) — número de casos em que o comportamento animal foi corretamente classificado como não sendo observado, Falso Positivo (FP) — número de casos em que o comportamento animal de interesse foi classificado incorretamente, mas não foi observado; e Falso Negativo (FN) — número de casos em que o comportamento animal de interesse foi observado visualmente, mas foi classificado incorretamente como algum outro comportamento animal (Quadro 1).

O quadro 1 exemplifica como uma matriz de confusão é construída e organizada para a realização dos cálculos das métricas da classe “visita ao cocho”, que avaliam o desempenho do “Random Forest”. Para cada comportamento, os valores de referência que determinam os VPs, os VNs, os FNs e os FPs são posicionados em locais diferentes na matriz de confusão, modificando sua interpretação.

Quadro 1. Exemplo de matriz de confusão considerada para cálculo de sensibilidade, especificidade, valor preditivo positivo e valor preditivo negativo para a classe “visita ao cocho”.

Matriz de confusão		Valor de referência		
Predição	Comportamentos	1	2	3
	1	Verdadeiro positivo	Falso positivo	Falso positivo
	2	Falso Negativo	Verdadeiro negativo	Verdadeiro negativo
	3	Falso Negativo	Verdadeiro negativo	Verdadeiro negativo

Fonte: a autora.

Para obtenção das métricas citadas para o conjunto de dados de teste, utilizou-se a função "confusion Matrix" do pacote caret (KUHN, 2008), no programa computacional R (versão 4.3.0 [2023-04-21]) (R CORE TEAM, 2023). A partir dessas classificações, obtidas pela matriz de confusão, foi possível calcular sensibilidade, especificidade, valor preditivo positivo (VPP), valor preditivo negativo (VPN) (Tabela 2) acurácia e coeficiente Kappa (KRAEMER, 1980).

Tabela 2. Parâmetros calculados através da matriz de confusão e seus significados.

Parâmetros	Equação	Significado
Sensibilidade	$\frac{VP}{VP+FN}$	Corresponde à proporção de casos positivos corretamente classificados em relação ao total de casos positivos reais.
Especificidade	$\frac{VN}{VN+FP}$	Corresponde à proporção de casos negativos corretamente classificados em relação ao total de casos negativos reais.
Valor Preditivo Positivo	$\frac{VP}{VP+FP}$	Mede a proporção de casos positivos corretamente previstos em relação ao total de casos previstos como positivos. Indica a probabilidade de que um caso previsto como positivo seja realmente positivo.
Valor Preditivo Negativo	$\frac{VN}{VN+FN}$	Mede a proporção de casos negativos corretamente previstos em relação ao total de casos previstos como negativos. Indica a probabilidade de que um caso previsto como negativo seja realmente negativo.

VP: Verdadeiro positivo; FN; Falso negativo; VN: Verdadeiro Negativo; FP: Falso Positivo. Fonte: Adaptado de Borchers *et al.* (2017).

O coeficiente kappa (k) é uma métrica estatística usada para avaliar a consistência e a confiabilidade de modelos de classificação, especialmente quando há desbalanceamento nas classes, quantificando a concordância observada entre as classificações quanto à concordância esperada por acaso (KRAEMER, 1980). Sua escala varia de -1 a 1, onde valores próximos a 1 indicam forte concordância entre as classificações, valores próximos a 0 indicam concordância próxima ao acaso e valores negativos indicam concordância pior do que o acaso (KRAEMER, 1980).

Com essas métricas, foi possível avaliar se a modificação no intervalo de tempo do comportamento observado (1, 5, 10 e 20 minutos) utilizado para treinar o

modelo, altera a habilidade de predição do comportamento animal nos dados de teste.

5. RESULTADOS E DISCUSSÃO

5.1 Frequência comportamental

As proporções para cada comportamento do total de 690.206 observações a cada 1 minuto foram 19,3%, 1,23% e 79,47%, dos quais representam o comportamento “visita ao cocho” (1), “visita ao bebedouro” (2) e “outras atividades” (3), respectivamente. Nestas 24 horas de filmagens realizadas durante o dia, essas proporções representaram 4,63 horas em que os bovinos realizaram o comportamento de visitas ao cocho, 0,30 horas sendo visita ao bebedouro e 19,07 horas em que os bovinos se dedicaram a outras atividades como ócio, ruminação ou interação com outros bovinos (tabela 3).

Referente às observações a cada 5 minutos, as proporções representaram 14,81%, 0,66% e 84,53%, dos quais são os comportamentos 1, 2 e 3, respectivamente. Neste caso, as proporções representaram 3,55h de visitas ao cocho, 0,16h de visitas ao bebedouro e 20,29h realizando outras atividades (tabela 3). Resultados similares foram obtidos por Argenta *et al.* (2013), que observaram o tempo despendido para as atividades de alimentação, ócio e ruminação de novilhos terminados em confinamento a cada cinco minutos, no decorrer de vinte e quatro horas, obtendo resultados de 4,29, 11,51 e 8,06 h/dia, respectivamente. Em concordância, Silva *et al.* (2005b) relataram que animais estabulados permanecem em torno de doze horas em ócio diariamente, somando valores de ócio em pé e deitado.

Diferentemente, Polli *et al.* (1995) observaram que bovinos em regime de confinamento semi coberto, observados a intervalos regulares de 5 minutos em condições de clima subtropical (temperatura média 15,2°C, umidade relativa 75,0%), alimentados à vontade com duas fontes de volumosos (70% da dieta total) e 30% de concentrado, passaram, em média, 21,1% do seu tempo realizando atividade de alimentação com pico nos horários de fornecimento de alimento no cocho às 9:00 am e 16:00 pm. Além disso, 40,7% do tempo permaneceram em ócio, 35,5% realizando ruminação e apresentaram apenas quatro acessos ao bebedouro.

Tabela 3. Período de permanência dos bovinos nas atividades durante as 24 horas de observação para os intervalos de tempo de 1, 5, 10 e 20 minutos.

Período observacional	Tempo de atividade (horas)		
	Visita ao cocho (1)	Visita ao Bebedouro (2)	Outras Atividades (3)
Obs. 1 min	4,63	0,30	19,07
Obs. 5 min	3,55	0,16	20,29
Obs. 10 min	4,0	0,30	19,7
Obs. 20 min	3,43	-	20,57

Em contrapartida, Segabinazzi *et al.* (2014) encontraram valores de 2,96 horas de alimentação (4,91 visitas ao comedouro, com duração média de 36,16 minutos) de bovinos confinados em baias individuais com intervalos de 5 minutos de observação, diferentemente dos animais mantidos a pasto também avaliados, que permanecem 40,1% de tempo a mais nessa atividade do que os confinados, sendo o tempo de deslocamento, a facilidade de busca, coleta e seleção do pasto os fatores que podem afetar a duração da atividade. Quanto a outras atividades, os animais confinados permaneceram mais tempo que os animais a pasto (6,98 vs 5,89 horas) (SEGABINAZZI *et al.*, 2014).

Com relação ao tempo gasto bebendo água, Segabinazzi *et al.* (2014) observaram que foi 91,8% maior para os animais confinados em relação aos que estavam em pastejo, totalizando 9,89 minutos, concluindo que a atividade de visitas ao bebedouro é influenciada por vários fatores, como a ingestão de matéria seca, a composição do alimento e a temperatura ambiente, atribuindo o estresse térmico como o precursor do maior consumo de água.

As observações a cada 10 minutos, por sua vez, apresentaram as proporções de 16,61% ou 4h para 1, 1,29% ou 0,30h para 2 e 82,10% ou 19,7h, para 3 (tabela 3). Em contrapartida, para as observações a cada 20 minutos, as proporções apresentaram os valores de 14,27% ou 3,43h e 85,73% ou 20,57h para os comportamentos “visita ao cocho” e “outras atividades”, sendo o comportamento “visita ao bebedouro” ausente nesse período de observação (tabela 3).

De acordo com Silva *et al.* (2005b), os animais que permanecem mais tempo ruminando deitados e em ócio deitado, favorecem o menor gasto de energia com a

atividade física, em função do menor deslocamento dentro das baias, proporcionando maior acúmulo de energia para a deposição de músculo e de gordura na carcaça. Em sua pesquisa, os animais permaneceram em média 6,68 e 7,10 h/dia do tempo realizando as atividades de ruminação e ócio deitados (SILVA *et al.*, 2005b). Os resultados das observações com relação à visita ao comedouro destes autores, mostraram que os animais apresentam maior frequência da atividade de ingestão de alimento nos horários próximos ao fornecimento das dietas, corroborando com Argenta *et al.* (2013).

As oscilações de tempo de permanência observadas dos comportamentos classificados como “outras atividades” comparados ao de outros autores provavelmente ocorrem devido a composição da dieta. Segabinazzi *et al.* (2014) verificaram que o consumo de partículas foliares maiores refletem em alterações na digestibilidade da matéria seca, devido ao maior tempo de retenção ruminal, consequentemente na redução do consumo de matéria seca (CMS) e intensificação dos processos de mastigação e ruminação, que também são influenciados pelo nível e tipo de fibra. Animais confinados tendem a receber alta porcentagem de concentrado em sua dieta, melhorando a digestibilidade da dieta (PINTO *et al.*, 2010), reduzindo o tempo de permanência do alimento no trato gastrointestinal, aumentando assim a taxa de passagem e consequentemente a ingestão de matéria seca (KONONOFF *et al.*, 2003). Outra questão que pode alterar o comportamento dos animais é o padrão racial e o temperamento dos animais.

Com relação aos comportamentos menos frequentes, Williams *et al.* (2020) verificaram em seu estudo que o uso de acelerômetros não foi capaz de classificar com precisão eventos de consumo curto (10 segundos ou menos de duração) usando modelos de frequência e um modelo linear de efeitos mistos, pois os comportamentos parecidos não eram corretamente distinguidos durante a predição, refletindo a ineficiência do treinamento dos modelos em detectar comportamentos menos frequentes e de baixa duração.

Além disso, observou que a duração do consumo de água por novilhas geralmente ocorria, em média, 46 segundos no total por visita no primeiro minuto após a entrada no ambiente onde havia os bebedouros monitorados. Quando as novilhas visitavam sozinhas o ambiente, o consumo variava de 2 a 76 s de duração (média de 18 s) (WILLIAMS *et al.*, 2020). Este fato também foi observado no

presente estudo, embora não quantificado por animal, o consumo de água foi naturalmente realizado em poucos segundos, o que influencia na proporção do aparecimento do comportamento entre maiores intervalos de tempo. Ainda assim, de acordo com Miller-Cushon *et al.*, (2015) e Hill *et al.*, (2017), existem poucos estudos associados a sistemas que ajudam a monitorar e classificar esses comportamentos menos frequentes, embora esses sejam indicativos de saúde e crescimento do animal.

5.2 Acurácia

A acurácia, a qual representa a taxa de acertos gerais, foi mais alta para os dados de teste quando a observação foi realizada em intervalos de 20 minutos (78,73%), seguida por intervalos de 1, 10 e 5 minutos (67,93%, 66,82% e 64,95%, respectivamente) (Tabela 4). No entanto, esse resultado provavelmente foi influenciado pela desproporção dos comportamentos observados, pois o modelo com intervalos de 20 minutos apresentou apenas as duas classes majoritárias, facilitando assim a predição desta situação.

Ao observar os resultados de acurácia, considera-se que o modelo apresentou desempenho satisfatório para a predição dos comportamentos considerados, principalmente ao realizar a predição da classe majoritária, o que pode conduzir à incorreta interpretação sobre a precisão do modelo. O algoritmo do *Random Forest* tem sido usado por vários autores para ajustar e treinar modelos por se apresentar altamente capaz de selecionar e classificar variáveis preditoras e discriminar entre variáveis preditas, utilizando as variáveis colhidas pelos acelerômetros (ALVARENGA *et al.*, 2016; WATANABE *et al.*, 2021) e, de forma geral, estes estudos apresentaram adequada acurácia no treinamento do modelo.

Tabela 4. Médias de Sensibilidade, Especificidade, Valor Preditivo Positivo, Valor Preditivo Negativo, Acurácia e coeficiente Kappa para os comportamentos estudados no intervalo de 1, 5, 10 e 20 minutos.

Algoritmos	Comportamentos			Acurácia	Kappa ¹
	Visita ao cocho (1)	Visita ao Bebedouro (2)	Outras Atividades (3)		
Obs. 1 min				0,6793	0,3559
Sensibilidade	0,69362	0,6891	0,6757		
Especificidade	0,82835	0,8420	0,8728		
VPP	0,49145	0,1689	0,9537		
VPN	0,91877	0,9954	0,4100		
Obs. 5 min				0,6495	0,2589
Sensibilidade	0,76727	0,9799	0,6262		
Especificidade	0,70455	0,9301	0,8094		
VPP ²	0,31107	0,0853	0,9472		
VPN ³	0,94572	0,9998	0,2838		
Obs. 10 min				0,6682	0,3170
Sensibilidade	0,8205	0,9810	0,6325		
Especificidade	0,7142	0,9357	0,8321		
VPP ²	0,3638	0,1662	0,9453		
VPN ³	0,9523	0,9997	0,3305		
Obs. 20 min				0,7873	0,4343
Sensibilidade	0,8986	-	-		
Especificidade	0,7688	-	-		
VPP ²	0,3928	-	-		
VPN ³	0,9785	-	-		

¹Kappa: Coeficiente Kappa. ²Verdadeiro preditivo positivo. ³Verdadeiro preditivo negativo.

5.3 Kappa

Da mesma maneira que a acurácia, o coeficiente Kappa trata-se da confiabilidade, ou seja, é um método estatístico para avaliar o nível de concordância entre o observado e o modelo previsto (KRAEMER, 1980). Um Kappa com valor 1 indica concordância perfeita, enquanto um Kappa de zero indica concordância equivalente ao acaso (ALVARENGA *et al.*, 2016). Nesse caso, o valor mais alto de kappa foi obtido na observação realizada em intervalos de 20 minutos (0,4343), depois para intervalos de 1, 10 e 5 minutos (0,3559, 0,3170 e 0,2589, respectivamente) (Tabela 4). Este melhor valor de Kappa para as observações a cada 20 minutos assemelha-se ao ocorrido com este intervalo ao observar a acurácia, ou seja, por ser representado apenas com as atividades majoritárias, o modelo apresentou menor dificuldade de predição, porém comportamentos que ocorreram não foram registrados por esse intervalo de tempo.

O menor valor de Kappa observado para o intervalo de 5 minutos pode ter sido influenciado pela amplitude das frequências dos diferentes comportamentos, sendo que variou de 0,66% (para classe 2) até 84,53% (para a classe 3), enquanto que os demais tiveram proporções maiores para a classe menos representada (1,23% e 1,29%) e proporções menores para as classes mais representadas (79,47% e 82,10%).

Bikker *et al.* (2014) obtiveram em seu estudo valores de Kappa iguais a 1 ao observar os comportamentos de ingestão de alimento, ruminação e descanso de vacas holandesas em galpão a partir de dados coletados em intervalos de 1 minuto com o sensor acoplado a um tag de orelha. Diferentemente do obtido no presente estudo que, mesmo realizando o balanceamento dos dados durante o treinamento, os dados de teste refletiram a desproporcionalidade entre os comportamentos observados, o que possivelmente resultou em menor Kappa nos conjuntos de dados que apresentaram maior desproporcionalidade (intervalo de observação de 5 minutos).

5.4 Sensibilidade

As maiores sensibilidades do modelo para a predição dos comportamentos obteve-se na observação a cada 20 minutos, onde 89,86% (0,8986) dos

comportamentos “visita ao cocho” foram corretamente classificados e o comportamento menos frequente não foi identificado, o que favoreceu na facilidade do modelo em prever os comportamentos 1 e 3. Na sequência, observa-se que a sensibilidade na predição de todos os comportamentos, o intervalo de 10 minutos obteve os maiores valores (82,05%, 98,10% e 63,25%, classes 1, 2 e 3, respectivamente). Para o comportamento menos frequente “consumo de água”, as maiores sensibilidade foram obtidas para a observação a cada 10 e 5 minutos (0,9810 e 0,9799), com valores inferiores para a observação de 1 minuto (0,6891) (Tabela 4).

Apesar desta alta sensibilidade indicar adequada eficiência no treinamento do modelo para identificar, distinguir e classificar de forma correta este comportamento, esse valor pode ter sido influenciado pela forma que o conjunto de dados foi construído, em que há preenchimento do comportamento observado nos minutos seguintes até atingir o limite de tempo para a próxima observação, acarretando no aumento da frequência do comportamento de visita ao bebedouro em momentos sequenciais, o que na realidade do confinamento não ocorre.

Watanabe *et al.* (2021) utilizando o método de reamostragem (Under-sampling) obtiveram alta sensibilidade e especificidade (80,8% e 94,8%, respectivamente) para o comportamento de consumo de água, com uma acurácia e Kappa de 64,7% e 50,5%, em contrapartida de um desempenho pouco inferior para os outros comportamentos mais frequentes avaliados, semelhantemente ao observado no presente estudo. Estes autores enfatizaram que a pequena diminuição ou nenhum ganho de sensibilidade observado para os comportamentos mais frequentes quando os métodos de reamostragem foram usados em RF, pode ter ocorrido devido à amostragem aleatória dessas classes de comportamento majoritário, levando a uma diminuição em suas taxas de verdadeiros positivos, mostrando que balanceamento da base de dados para equalizar o número de observações só deve ser feito quando a classe de interesse for a minoritária (WATANABE *et al.*, 2021).

Para contornar essa situação, Watanabe *et al.* (2021) utilizaram o método de treinamento over-sampling, que aumenta o número de observações para as classes minoritárias de comportamento sem prejudicar a classificação das classes

majoritárias, demonstrando que o RF, dentro dos algoritmos e técnicas testadas, foi o que melhor conseguiu classificar os comportamentos estudados.

5.5 Especificidade

A especificidade, por sua vez, indica uma melhor capacidade do modelo em distinguir e classificar corretamente comportamentos que não pertencem a classe. A maior especificidade para os comportamentos 1 e 3 foi apresentada no intervalo de observação de 1 minuto, representando 82,83% e 87,20% dos comportamentos que o modelo conseguiu prever que não pertenciam a determinada classe. No caso do comportamento 2, as observações a cada 10 e 5 minutos obtiveram os valores mais altos (93,57% e 93,01%, respectivamente) (Tabela 4), apresentando adequada habilidade em prever a ausência deste comportamento quando ele não ocorreu.

Todavia, semelhante ao que foi observado para sensibilidade, a especificidade também possui influência em como os arquivos de dados foram formados, podendo acarretar em favorecimento sobre a classificação dos comportamentos em relação ao que ocorre na realidade. Ao comparar os comportamentos preditos pelos modelos dos intervalos de 5, 10 e 20 minutos e o comportamento observado no intervalo de 1 minuto, a especificidade do comportamento 1 foi maior no intervalo de 20 minutos, acertando 71,5% das vezes que o classificou como sendo 1. Os maiores valores para o comportamento 3 se assemelham nos intervalos de 5 e 10 minutos (56,7% e 53,7%, respectivamente). Para o comportamento 2, todos os modelos apresentaram alta especificidade, com valores de 92,42%, 92,22% e 100% para os intervalos de 5, 10 e 20 minutos respectivamente.

Dessa forma, ao comparar os valores reais do intervalo de 1 minuto com os valores preditos dos demais intervalos, o modelo foi capaz de prever com mais assertividade os comportamentos que não pertenciam a classe analisada do que os comportamentos que realmente pertenciam, para todos os intervalos de tempo dos comportamentos com menor observações (1 e 2). No caso do comportamento 3, o modelo obteve valores semelhantes de especificidade para o intervalo de 5 e 10 minutos (56,7% e 53,7%, respectivamente) e também para sensibilidade (58,42% e 56,76, respectivamente). Quanto ao intervalo de 20 minutos para este comportamento (3), a sensibilidade reduz para 49,18% e a especificidade aumenta

para 71,64%, sugerindo que o modelo tende a ser mais preciso a identificar comportamentos classificados como verdadeiros positivos conforme o intervalo de observações aumenta, mas reduz sua taxa de acerto quanto aos comportamentos que não pertenciam a classe com maior número de observações “outras atividades”.

5.6 Valor Preditivo Positivo

O Valor Preditivo Positivo (VPP) trata-se da proporção de casos positivos previstos que estavam corretos (ALVARENGA *et al.*, 2016). Os melhores valores de VPP obtidos neste estudo foram para o intervalo de observação de 1 minuto, indicando uma taxa de assertividade de 49,14% para a classe 1, 16,89% para a classe 2 e 95,37% para a classe 3 de instâncias classificadas como um comportamento corretamente em relação ao total de instâncias classificadas como sendo aquele comportamento. O alto valor de VPP obtido para a classe 3 auxilia na indicação de eficiência do treinamento do modelo para comportamentos mais frequentes e de longa duração. Em contrapartida, Vázquez-Diosdado *et al.* (2015) encontraram VPP de 92,0, 93,3, 93,1% para os intervalos de observação de 1, 5 e 10 minutos quando analisaram o comportamento de alimentação de vacas leiteiras em ambientes fechados.

Ao observar os comportamentos 1 e 2 (menor número de observações comparado ao total), o intervalo de observação de 10 minutos assemelhou-se ao intervalo de 1 minuto, com 36,38% de acertos para a classe 1 e 16,62% para a classe 2, demonstrando que a reamostragem de dados beneficia o treinamento da máquina para interpretar comportamentos menos frequentes, em contrapartida da redução da eficiência de maiores intervalos de observação para as atividades de maior frequência, como mostra o VPP para o comportamento 3 nos diferentes intervalos de tempo (95,37%, 94,72%, 94,53% e 39,28% para os intervalos de 1, 5, 10 e 20 minutos, respectivamente).

O menor valor de VPP foi obtido no intervalo de 5 minutos para o comportamento 2, sendo apenas 8,53% dos dados classificados corretamente em relação ao total de instâncias classificadas como sendo o comportamento específico. Esse valor é reflexo da proporção de observações do comportamento em relação ao seu total (0,66% do total de dados observados no intervalo de tempo), e também quando comparado ao de outros intervalos de observação — 1,29% e 1,23%, para

os intervalos de 10 e 1 minuto, respectivamente. Todavia, mesmo que a proporção do número de observações de visita ao bebedouro tenha sido menor para o intervalo de 5 minutos, a predição do comportamento 2 para o mesmo teve alta sensibilidade, que indica a proporção de casos positivos corretamente classificados em relação ao total de casos positivos reais, em contrapartida de muitos erros com relação a proporção de casos positivos corretamente previstos em relação ao total de casos previstos como positivos, baixando o valor de VPP.

5.7 Valor Preditivo Negativo

Ao contrário do VPP, o VPN indica a proporção de resultados negativos na classificação. Para o comportamento 1, o VPN aumentou conforme o aumento do intervalo de tempo de observação e para o comportamento 3 foi observado o contrário, em que o valor de VPN reduziu (41%, 28,3% e 33,05% para observações de 1, 5 e 10 minutos, respectivamente), indicando declínio em sua capacidade de classificar comportamentos que não pertencem a classe corretamente. Desta forma, ao comparar os valores preditos com relação ao intervalo de 1 minuto, o modelo é mais eficaz em prever os comportamentos que não pertencem a determinada classe para os comportamentos de menor frequência (1 e 2, sendo 85,65% e 98,77% os maiores valores apresentados para o intervalo de 20 minutos) dos que os que pertencem.

5.8 Comparação da precisão dos comportamentos preditos com base no intervalo de 1 minuto

Ao comparar a porcentagem de assertividade da predição dos modelos nos intervalos de 5, 10 e 20 minutos quando utilizado para o cálculo das métricas de avaliação o comportamento observado com intervalo de 1 minuto, considerado neste estudo sendo o intervalo que mais aproxima-se da realidade, obtemos os valores de acertos reais para estes intervalos.

O comportamento 1 apresentou maior sensibilidade no intervalo de observações de 5 minutos (50,10%), seguido do intervalo de 20 e 10 minutos (49,9% e 47,07%, respectivamente). Com relação a especificidade, o intervalo de 20 minutos apresentou 71,5% de acertos, seguido do intervalo de 5 minutos (66%) (Tabela 5).

Tabela 5. Médias de assertividade para Sensibilidade, Especificidade, Valor Preditivo Positivo, Valor Preditivo Negativo, Acurácia e coeficiente Kappa para os comportamentos preditos pelos modelos treinados com intervalo 5, 10 e 20 minutos comparados com os comportamentos observados com intervalo de 1 minuto.

Algoritmos	Comportamentos			Acurácia	Kappa ¹
	Visita ao cocho (1)	Visita ao Bebedouro (2)	Outras Atividades (3)		
Obs. 5 min				0,5617	0,1014
Sensibilidade	0,501035	0,0573	0,5842		
Especificidade	0,66	0,9242	0,567		
VPP ²	0,26056	0,0093	0,8392		
VPN ³	0,8469	0,987	0,2603		
Obs. 10 min				0,5427	0,0712
Sensibilidade	0,47074	0,05827	0,5676		
Especificidade	0,6462	0,9222	0,5373		
VPP ²	0,2413	0,009224	0,82625		
VPN ³	0,8363	0,9875	0,2429		
Obs. 20 min				0,6657	0,1676
Sensibilidade	0,499	0	0,7164		
Especificidade	0,715	1	0,4918		
VPP ²	0,2924	0	0,8452		
VPN ³	0,8565	0,9877	0,30935		

¹Kappa: Coeficiente Kappa. ²Verdadeiro preditivo positivo. ³Verdadeiro preditivo negativo.

Para o comportamento 2 no intervalo de 5 minutos a sensibilidade apresentou 0,0573, em que o modelo conseguiu acertar apenas 5,73% dos comportamentos classificados no modelo de 1 minuto. Para o intervalo de 10 minutos de observação, a sensibilidade foi de 5,82%, verificando-se que os resultados preditos se apresentam distantes do ocorrido na realidade do intervalo de observações de 1 minuto. Isso ocorreu devido ao método de treinamento utilizado para as classificações, em que este foi preciso em identificar e classificar os

comportamentos, mas não sobre a percepção de como ocorre na realidade. Além disso, conforme o intervalo de tempo aumenta, há uma perda maior de informações, principalmente de comportamentos menos frequentes e de curta duração (FISCHER *et al.*, 2000). Apesar do intervalo de observações de 10 minutos apresentar desempenho semelhante ao intervalo de 1 minuto, ao comparar os modelos com a realidade de 1 minuto o intervalo de 5 minutos de observação obteve melhores resultados, comprovando que o treinamento e desempenho do modelo são mais eficientes utilizando intervalos de observação curtos, principalmente quando o objetivo for avaliar comportamentos menos frequentes e de curta duração.

Para a classe 3, observaram-se maiores sensibilidades para o intervalo de 20 minutos, mas sua especificidade foi baixa (49,18%) quando comparada ao maior valor apresentado no intervalo de 5 minutos (56,7%). Quanto ao VPP, somente a classe 3 de todos os intervalos de tempo obtiveram valores acima de 80%, sendo o segundo maior valor para a classe 1 do intervalo de 20 minutos (29,24%).

Zhang *et al.* (2020) afirmaram em seu estudo que grandes conjuntos de dados de aprendizado de máquina, como esses dados de acelerômetro, estão sujeitos a dois erros principais na classificação: erro de treinamento e erro de generalização. De acordo com Sprinkle *et al.*, (2021), o erro de treinamento é a falta de ajuste do modelo preditivo escolhido para os dados de treinamento conhecidos para classificar com precisão os dados conhecidos. O erro de generalização, por sua vez, é a falha dos dados de treinamento em prever e classificar adequadamente os dados desconhecidos. À medida que o tamanho do conjunto de dados desconhecido aumenta (em comparação com os dados de teste conhecidos), os erros de generalização aumentam (ZHANG *et al.*, 2020), o que pôde ser observado no presente trabalho ao utilizar a subamostragem nos dados de treino, mas realizar a predição com um banco de dados total.

As incorretas classificações para os comportamentos de menor frequência também foram relatadas por Williams *et al.*, (2017), em que o treinamento do algoritmo foi baseado na observação de que, quando o gado bebe de um cocho, ele assume uma posição única de cabeça e pescoço (inclinado para baixo e para frente) com relativamente pouca atividade de cabeça e pescoço além da deglutição. O algoritmo foi capaz de identificar eventos de beber de eventos de não beber com postura cabeça-pescoço alta (por exemplo, levantar a cabeça) e atividade de

pescoço alto (por exemplo, caminhar), mas não foi capaz de separar eventos de não-beber com postura cabeça-pescoço semelhante e atividade para beber (WILLIAMS *et al.*, 2017).

Sprinkle *et al.*, (2021), por sua vez, utilizando o método de validação cruzada dos dados e RF para classificação de comportamentos de vacas em pastejo, encontraram uma taxa de erro geral de 6,7%, classificada pelos autores como baixa, mas destacaram que o grande desafio a ser superado com erro de generalização para dados de acelerômetro é obter comportamento observado suficiente para treinar e classificar adequadamente os dados.

Embora o modelo não tenha apresentado maior sensibilidade para atividades menos frequentes, recomenda-se treinar o modelo com observações em curto intervalo de tempo (como 1 minuto), devido ao melhor equilíbrio entre todas as métricas considerando todos os comportamentos, especialmente quando o interesse for verificar o consumo de água pelos animais, dada a importância da mesma para a produtividade. Ainda assim, neste caso, visto que o ajuste de dados na fase de teste acarretou em redução da sensibilidade (acertos) para os comportamentos de maior frequência, é importante proporcionar um treinamento da máquina de forma que o modelo consiga prever os comportamentos menos frequentes sem alterar de forma significativa a detecção dos comportamentos frequentes, como é o caso das visitas ao cocho, ócio e ruminação, pois eles fornecem dados preciosos quanto a saúde e bem-estar dos animais.

Em outros casos, se o objetivo final do treinamento do modelo for apenas o valor relativo do comportamento, ou seja, pretende-se comparar tratamentos sem que o valor de tempo gasto em cada atividade seja relevante, e que não se tenha recursos humanos para realizar a observação a cada um minuto para treinar o modelo, modelos com o intervalo de 10 minutos podem ser explorados, uma vez que este apresentou boa predição e o viés será observado para todos os tratamentos testados. Porém, para as atividades menos frequentes os valores preditos não indicarão a realidade quando comparado com os valores obtidos através do treinamento de 1 minuto.

De forma geral, o uso de acelerômetros para classificar e prever o comportamento animal é uma ferramenta para monitoramento contínuo dos animais. Portanto, o correto treinamento da máquina é de grande importância para o

processo de identificação correta dos comportamentos dos bovinos em tempo real e permite que, em um ambiente onde o monitoramento dos bovinos é implantado, possa fornecer dados precisos sobre sua real situação no confinamento. Além disso, sugere-se mais estudos utilizando a mesma metodologia de avaliação, mas registrando as observações de acordo com a mudança do comportamento para treinamento dos modelos.

6. CONCLUSÃO

Neste estudo foi possível verificar que a habilidade de predição do modelo modificou conforme o intervalo de observação foi alterado. Em geral, os modelos apresentaram habilidade de predição do comportamento animal satisfatória, porém quando comparado à realidade, sua precisão reduziu conforme o intervalo de tempo de observação se elevou. Assim, recomenda-se o treinamento do modelo para obter melhor desempenho na predição utilizando o intervalo de 1 minuto, principalmente se o objetivo for detectar comportamentos menos frequentes. Em casos de poucos recursos humanos para monitoramento dos bovinos, se o objetivo for avaliar comportamentos mais frequentes, o modelo de 10 minutos pode ser satisfatório.

7. REFERÊNCIAS BIBLIOGRÁFICAS

ABRAHAMSSON, P. Furnished cages and aviaries for laying hens. Effects on production, health and use of facilities. Swoish University of Agricultural Sciences, Upsala. Department of Animal Nutrition and Management, 1996.

ABIEC, Associação Brasileira das Indústrias Exportadoras de Carnes. **BEEF REPORT**: Perfil da pecuária no Brasil. 2021. Disponível em: <http://abiec.com.br/publicacoes/beef-report-2021/>. Acesso em: 05 fev. 2022.

ABIEC, Associação Brasileira das Indústrias Exportadoras de Carnes. **BEEF REPORT**: Perfil da pecuária no Brasil. 2022. Disponível em: <https://www.abiec.com.br/publicacoes/beef-report-2022/>. Acesso em: 04 jun. 2023.

ABIEC, Associação Brasileira das Indústrias Exportadoras de Carnes. **BEEF REPORT**: Perfil da pecuária no Brasil. 2023. Disponível em:

<https://www.abiec.com.br/publicacoes/beef-report-2023-capitulo-02/>. Acesso em: 04 jun. 2023.

ADAMCZYK, K. *et al.* Genetic analysis and evaluation of behavioural traits in cattle. **Livestock Science**, [S.L.], v. 154, n. 1-3, p. 1-12, jun. 2013. Elsevier BV. <http://dx.doi.org/10.1016/j.livsci.2013.01.016>.

ALPAYDIN, E. Introduction to machine learning. MIT Press, 2014.

ALVARENGA, F. A. P. *et al.* Using a three-axis accelerometer to identify and classify sheep behavior at pasture. **Applied Animal Behaviour Science**. v.181, p.91-99, 2016.

AMMER, S., *et al.*, 2017. Impacto da composição da dieta e índice de temperatura e umidade na ingestão de água e matéria seca de vacas leiteiras de alto rendimento. *J. Anim. Physiol. Anim. nutr. (Berl)*. <https://doi.org/10.1111/jpn.12664>.

ARGENTA, F. M. *et al.* Comportamento ingestivo de novilhos alimentados com silagem de capim papuã (*Urochloa Plantaginea*) x silagem de sorgo (*Sorghum bicolor* (L.) Moench). **Rev. Acad., Ciênc. Agrár. Ambient.**, Curitiba, v. 11, n. 3, p. 243-253, fev. 2013. Doi:10.7213/academica.011.00.

ARGENTA, F. M. *et al.* Padrões comportamentais de bovinos confinados com grãos de milho, aveia branca ou arroz com casca. **Ciência Animal Brasileira**, [S.L.], v. 20, p. 1-13, set. 2019. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/1809-6891v20e-49508>.

BAILEY, D. W. *et al.* Use of GPS tracking collars and accelerometers for rangeland livestock production research. **Translational Animal Science**, [S.L.], v. 2, n. 1, p. 81-88, 25 jan. 2018. Oxford University Press (OUP). <http://dx.doi.org/10.1093/tas/txx006>.

BEATTY, D. T. *et al.* Physiological responses of *Bos taurus* and *Bos indicus* cattle to prolonged continuous heat and humidity. **J. Anim. Sci.** 84, p. 972–985, 2006.

BENAISSA, S. *et al.* Classification of ingestive-related cow behaviours using RumiWatch halter and neck-mounted accelerometers. **Applied Animal Behaviour**

Science, v. 211, p. 9-16, fev. 2019. Elsevier BV.
<http://dx.doi.org/10.1016/j.applanim.2018.12.003>.

BIKKER, J. P., *et al.* Technical note: evaluation of an ear-attached movement sensor to record cow feeding behavior and activity. **J. Dairy Sci.** 97, 2974–2979, 2014.

<http://dx.doi.org/10.3168/jds.2013-7560>.

BORCHERS, M. R. *et al.* Machine-learning-based calving prediction from activity, lying, and ruminating behaviors in dairy cattle. **Journal of dairy science**, v. 100, n. 7, p. 5664-5674, 2017.

BREIMAN, L. Random Forest. *Machine Learning*, v.45, p.5-32, 2001.

BREW, M. N. *et al.* Water intake and factors affecting water intake of growing beef cattle. **Livestock Science**, v. 140, p. 297-300, 2011.

BÜRGER, P. J. *et al.* Comportamento ingestivo em bezerros holandeses alimentados com dietas contendo diferentes níveis de concentrado. **Revista Brasileira de Zootecnia**, v. 39, n. 1, p. 236-242, 2000.

CARDOSO, A. R. *et al.* Comportamento ingestivo de cordeiros alimentados com dietas contendo diferentes níveis de fibra em detergente neutro. **Ciência Rural**, 36: 604-609, 2006.

CARVALHO, S. *et al.* Comportamento ingestivo de cordeiros texel e ideal alimentados com casca de soja. **Arch. Zootec.**, Santa Maria, 63 (241): 55-64. 2014.

CASANOVA, P. T. (2020). Avaliação do uso de acelerômetro na observação do comportamento ingestivo de bovinos em pastejo (Tese de doutorado, Universidade Federal de Santa Maria).

CAVALCANTI, L. F. L.; RIBAS, M. N.; PEREIRA, L. G. R. *Zootecnia de Precisão em Bovinocultura de Leite*. Belo Horizonte: FEP MVZ Editora, p. 86-96, 2015.

FERREIRA, S. F. *et al.* Fatores que afetam o consumo alimentar de bovinos. *Arquivos de Pesquisa Animal*, v.2, n.1, p.9 - 19, 2013.

FISCHER, V. *et al.* Aplicação de probabilidades de transição de estado dependentes do tempo na análise quantitativa do comportamento ingestivo de ovinos. Parte I. **Revista Brasileira de Zootecnia**, v.29, n.6, p.1811- 1820, 2000.

FREITAS, L. S. *et al.* Substituição da silagem de milho por silagem de girassol na dieta de novilhos confinados: comportamento ingestivo. **Revista Brasileira de Zootecnia**, v. 39, n. 1, p. 225-232, 2010. doi:10.1590/S1516-35982010000100030.

GONZÁLEZ, L. A. *et al.* Behavioral classification of data from collars containing motion sensors in grazing cattle. **Computers And Electronics in Agriculture**, [S.L.], v. 110, p. 91-102, jan. 2015. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2014.10.018>.

GUIROY, P. J. *et al.* Predicting individual feed requirements of cattle in groups. **J. Anim. Sci.** **79**, p. 1983–1995, 2001.

HAIXIANG, G. *et al.* Learning from class-imbalanced data: Review of methods and applications. **Expert Syst. Appl.** 2017, 73, 220–239.

HAMILTON, A. *et al.* Identification of the Rumination in Cattle Using Support Vector Machines with Motion-Sensitive Bolus Sensors. **Sensors**, v. 19, n. 5, p. 1165, 7 mar. 2019. MDPI AG. <http://dx.doi.org/10.3390/s19051165>.

HILL, T. M. *et al.* Technical Note: Evaluation of an ear-attached movement sensor to record rumination, eating, and activity behaviors in 1-month-old calves. **Prof. Anim. Sci.** 2017, 33, 743–747.

KOENING, K. M. *et al.* Optimum roughage proportion in barley-based feedlot cattle diets: Growth performance, feeding behaviour, and carcass traits. **Journal of Animal Science**, v.98, skaa299, 2020.

KONONOFF, P. J.; HEINRICHS, A. J.; LEHMAN, H. A. O efeito do tamanho da partícula de silagem de milho no comportamento alimentar, atividades de mastigação e fermentação ruminal em vacas leiteiras em lactação. **Journal Dairy of Science**, v. 86, n. 10, pág. 3343-3353, 2003.

KRAEMER, H. C. Extension of the kappa coefficient. **Biometrics**, 1980, 36, 207–216.

KUHN, M. Building predictive models in R using the caret package. *J. Stat. Softw.* 2008, 28, 1–26.

LIAKOS, K. *et al.* Machine Learning in Agriculture: a review. **Sensors**, [S.L.], v. 18, n. 8, p. 2674, 14 ago. 2018. MDPI AG. <http://dx.doi.org/10.3390/s18082674>.

LÓPEZ, V. *et al.* An insight into classification with imbalanced data: Empirical results and current trends on using data intrinsic characteristics. **Inf. Sci.** 2013, 250, 113–141.

MAHESH, B. Machine learning algorithms - a review. **International Journal of Science and Research (IJSR)**. [Internet], v. 9, p. 381-386, 2020.

MEGETO, G. A. S. *et al.* Artificial intelligence applications in the agriculture 4.0. **Revista Ciência Agronômica**, v. 51, n. 5, 2020. GN1 Genesis Network. <http://dx.doi.org/10.5935/1806-6690.20200084>.

MEKONNEN, M. M.; HOEKSTRA, A. Y. A Global Assessment of the Water Footprint of Farm Animal Products. **Ecosystems**, [S.L.], v. 15, n. 3, p. 401-415, 24 jan. 2012. Springer Science and Business Media LLC. <http://dx.doi.org/10.1007/s10021-011-9517-8>.

MENDONÇA, S. S. *et al.* Comportamento ingestivo de vacas leiteiras alimentadas com dietas à base de cana-de-açúcar ou silagem de milho. **Revista Brasileira de Zootecnia**, v. 33, n. 3, p. 723-728, 2004. doi:10.1590/S1516-35982004000300021.

MILLER-CUSHON, E. K.; DEVRIES, T. J. Invited review: Development and expression of dairy calf feeding behaviour. *Can. J. Anim. Sci.* 2015, 95, 341–350.

MIZUBUTI, I. Y. *et al.* Ingestive behavior of Nellore steers in feedlot fed with diets containing different corn hybrids. **Semina: Ciências Agrárias**, Londrina, v. 34, n. 6, p. 4203-4212, fev. 2013. DOI: 10.5433/1679-0359.2013v34n6Supl2p4203.

MOGAMI, C. A. Desenvolvimento de metodologias para determinação do bem estar e massa corporal de frangos de corte por meio de análise digital de imagens. Doctor, p. 101, 2009.

NEETHIRAJAN, S. The role of sensors, big data and machine learning in modern animal farming. **Sensing and Bio-Sensing Research**, v. 29, p. 100367, 2020.

ORTÊNCIO, M. O. et al. Ingestive behavior of calves fed diets based on corn grain and supplementary hay. **Brazilian Journal Of Development**, [S.L.], v. 6, n. 6, p. 38562-38574, 2020. <http://dx.doi.org/10.34117/bjdv6n6-412>.

PALHARES, J. C. P., MORELLI, M., & NOVELLI, T. I. Water footprint of a tropical beef cattle production system: The impact of individual-animal and feed management. **Advances in Water Resources**, v. 149, p. 103853, 2021. doi:10.1016/j.advwatres.2021.1038

PAULA FILHO, P. et al. Utilização de um Sistema de Visão Computacional para o Controle de um Robô Móvel. 9th Brazilian Conference on Dynamics Control and their Applications, 2010, pp. 817–823.

PAVLOVIC, D. et al. Classification of Cattle Behaviours Using Neck-Mounted Accelerometer-Equipped Collars and Convolutional Neural Networks. **Sensors**, v. 21, n. 12, p. 4050, 12 jun. 2021. MDPI AG. <http://dx.doi.org/10.3390/s21124050>.

PINTO, A. P. et al. Comportamento e eficiência ingestiva de tourinhos mestiços confinados com três dietas diferentes. **Archivos de Zootecnia**, v. 59, n. 227, p. 427-434, 2010.

POLLI, V. A. et al. Comportamento de bovinos e bubalinos em regime de confinamento. **Ciência Rural**, v. 25, n. 1, p. 127-131, 1995. FapUNIFESP (SciELO). <http://dx.doi.org/10.1590/s0103-84781995000100024>.

R CORE TEAM. R: A language and environment for statistical computing. Viena: R Foundation for Statistical Computing. Disponível em: <http://www.R-project.org/>. Acesso em: maio de 2023.

ROMANZINI, E. P. et al. Modern livestock farming under tropical conditions using sensors in grazing systems. **Scientific Reports**, v. 12, n. 1, p. 1-10, 16 fev. 2022. Springer Science and Business Media LLC. <http://dx.doi.org/10.1038/s41598-022-06650-5>.

SEGABINAZZI, L. R. et al. Diurnal ingestive behavior of Holstein calves reared in different systems: feedlot or pasture. **Acta Scientiarum. Animal Sciences**, [S.L.], v. 36, n. 2, p. 225, 8 maio 2014. Universidade Estadual de Maringá. <http://dx.doi.org/10.4025/actascianimsci.v36i2.22653>.

SANTOS, M. C. **Comportamento ingestivo de novilhos mestiços confinados: avaliados sob os métodos visual e eletrônico**. 2019. 66 f. Dissertação (Mestrado) - Curso de Zootecnia, Programa de Pós-Graduação em Zootecnia, Universidade Estadual do Sudoeste da Bahia, Itapetinga, 2019.

SANTOS, M. C. *et al.* Nutrient intake and ingestive behavior of feedlot steers fed with licuri cake. **Tropical Animal Health and Production (2020)**, Itapetinga, Ba, Brazil, v. 52: 1803-1809, 08 jan. 2020.

SHAHINFAR, S. *et al.* Prediction of insemination outcomes in Holstein dairy cattle using alternative machine learning algorithms. **Journal Dairy Science**, v.97, p.731-742, 2014.

SHAHRIAR, M. S., *et al.* Detecting heat events in dairy cows using accelerometers and unsupervised learning. **Computers And Electronics In Agriculture**, v. 128, p. 20-26, out. 2016. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2016.08.009>.

SILVA, R. R. *et al.* Avaliação do comportamento ingestivo de novilhas 3/4 holandês x zebu alimentadas com silagem de capim-elefante acrescida de 10% de farelo de mandioca. **Ciência Animal Brasileira**, v.6, n.3, p.134-141, 2005a.

SILVA, R. R. *et al.* Comportamento ingestivo de novilhas mestiças de holandês x zebu confinadas. **Archivos de Zootecnia**, v. 54, n. 205, p. 75-85, 2005b.

SOUSA, D. G. Estudo dos dados de plataformas de obtenção do peso e do consumo de água em tempo real para bovinos de corte. 2022. Dissertação (Mestrado em Ciência Animal e Pastagens) - Escola Superior de Agricultura Luiz de Queiroz, University of São Paulo, Piracicaba, 2022. [doi:10.11606/D.11.2021.tde-11042022-152715](https://doi.org/10.11606/D.11.2021.tde-11042022-152715). Acesso em: 2023-06-05.

SOUZA, S. R. M. B. O. *et al.* Comportamento ingestivo diurno de bovinos em confinamento e em pastagens. **Archivos de Zootecnia**, v. 56, n. 213, p. 67-70, 2007.

SPRINKLE, J. E. *et al.* Predicting cattle grazing behavior on rangeland using accelerometers. *Rangel. Ecol. Manag.* 2021, 76, 157–170.

TOBIN, C. *et al.* Sensor-based disease detection: a case study using accelerometers to recognize symptoms of bovine ephemeral fever. **Computers And Electronics In Agriculture**, v. 175, p. 105605, ago. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2020.105605>.

TRAN, D. *et al.* An IoT-based Design Using Accelerometers in Animal Behavior Recognition Systems. **Ieee Sensors Journal**, 2021. Institute of Electrical and Electronics Engineers (IEEE). <http://dx.doi.org/10.1109/jsen.2021.3051194>.

UNGAR, E. D. *et al.* Inference of Animal Activity from GPS Collar Data on Free-Ranging Cattle. **Rangeland Ecology & Management**, v. 58, n. 3, p. 256-266, maio 2005. Elsevier BV.

VALENTE, E. E. L. *et al.* Grazing Behavior and Locomotion of Young Bulls Receiving Different Nutritional Plans in a Tropical Pasture. **Asian Australasian Journal of Animal Sciences**, v. 26, n. 12, p. 1717-1725, 2013.

VAN SOEST, P. J. *et al.* Carbohydrate methodology, metabolism, and nutritional implications in dairy cattle: methods for dietary fiber, neutral detergent fiber, and nonstarch polysaccharides in relation to animal nutrition. **Journal Dairy Science**, NY, v. 74, p. 3583-3597, 1991.

VÁZQUEZ-DIOSDADO, J. A., *et al.* Classification of behaviour in housed dairy cows using an accelerometer-based activity monitoring system. **Anim. Biotelem.** 3, 15, 2015. <http://dx.doi.org/10.1186/s40317-015-0045-8>.

WATANABE, R. N. *et al.* Strategy to Predict High and Low-Frequency Behaviors Using Triaxial Accelerometers in Grazing of Beef Cattle. **Animals**, 2021, 11, 3438. <https://doi.org/10.3390/ani11123438>.

WELCH, J. G. Rumination, particle size and passage from the rumen. **Journal of Animal Science**, v. 54, n. 4, p. 885-894, 1982.

WERNER, J. *et al.* Evaluation and application potential of an accelerometer-based collar device for measuring grazing behavior of dairy cows. **Animal**, v. 13, n. 9, p. 2070-2079, 2019. Elsevier BV. <http://dx.doi.org/10.1017/s1751731118003658>.

WILLIAMS, L. R. *et al.* Application of accelerometers to record drinking behaviour of beef cattle. **Animal Production Science**, v. 59, n. 1, p. 122, 2017. CSIRO Publishing. <http://dx.doi.org/10.1071/an17052>.

WILLIAMS, L. R. *et al.* A sensor-based solution to monitor grazing cattle drinking behaviour and water intake. *Computers And Electronics In Agriculture*, v. 168, p. 105141, jan. 2020. Elsevier BV. <http://dx.doi.org/10.1016/j.compag.2019.105141>.

ZHENG, Z.; CAI, Y.; LI, Y. Oversampling method for imbalanced classification. **Comput. Inform.** 2015, 34, 1017–1037.

ZHANG, A., *et al.* 2020. Dive into Deep Learning, release 0.14.3. Online open source book. Disponível em: <https://d2l.ai/index.html#>. Acesso em: 06 Junho, 2023.