



**UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA**

**DETECÇÃO DE ESTRO EM NOVILHAS LEITEIRAS COM BASE
EM DADOS DE COCHOS E BEBEDOUROS ELETRÔNICOS**

Autor: Frederico Correia Cairo
Orientador: Luiz Gustavo Ribeiro Pereira

ITAPETINGA
BAHIA – BRASIL
Fevereiro de 2019

FREDERICO CORREIA CAIRO

**DETECÇÃO DE ESTRO EM NOVILHAS LEITEIRAS COM BASE
EM DADOS DE COCHOS E BEBEDOUROS ELETRÔNICOS**

Dissertação apresentada, como parte das exigências para obtenção do título de MESTRE EM ZOOTECNIA, no Programa de Pós-Graduação em Zootecnia da Universidade Estadual do Sudoeste da Bahia.

Orientador: Prof. Dr. Luiz Gustavo Ribeiro Pereira

Co-orientadores: Dr. João Ricardo Rebouças Dórea
Dra. Mariana Magalhães Campos

ITAPETINGA
BAHIA – BRASIL
Fevereiro de 2019

636.214 Cairo, Frederico Correia.

C137d Detecção de estro em novilhas leiteiras com base em dados de cochos e bebedouros eletrônicos. / Frederico Correia Cairo. - Itapetinga: Universidade Estadual do Sudoeste da Bahia, 2019.
54fl.

Dissertação apresentada, como parte das exigências para obtenção do título de MESTRE EM ZOOTECNIA, no Programa de Pós-Graduação em Zootecnia da Universidade Estadual do Sudoeste da Bahia. Sob a orientação do Prof. D. Sc. Luiz Gustavo Ribeiro Pereira e coorientação do Prof. D.Sc. João Ricardo Rebouças Dórea e Prof^a. D.Sc. Mariana Magalhães Campos.

1. Novilhas leiteiras – Modelagem - Detecção antecipada do estro. 2. Reprodução – Pecuária de precisão - *Randon forest*. 3. Bovinos – Cochos e bebedouros eletrônicos - *Machine learning*. I. Universidade Estadual do Sudoeste da Bahia. Programa de Pós-Graduação em Zootecnia. II. Pereira, Luiz Gustavo Ribeiro. III. Dórea, João Ricardo Rebouças. IV. Campos, Mariana Magalhães. V. Título.

CDD(21): 636.214

Catálogo na fonte:

Adalice Gustavo da Silva – CRB/5-535
Bibliotecária – UESB – Campus de Itapetinga-BA

Índice Sistemático para Desdobramento por Assunto:

1. Novilhas leiteiras – Modelagem - Detecção antecipada do astro
2. Reprodução – Pecuária de precisão - *Randon forest*
3. Bovinos – Cochos e bebedouros eletrônicos - *Machine learning*

UNIVERSIDADE ESTADUAL DO SUDOESTE DA BAHIA - UESB
PROGRAMA DE PÓS-GRADUAÇÃO EM ZOOTECNIA - PPZ
Área de Concentração: Produção de Ruminantes

Campus Itapetinga-BA

DECLARAÇÃO DE APROVAÇÃO

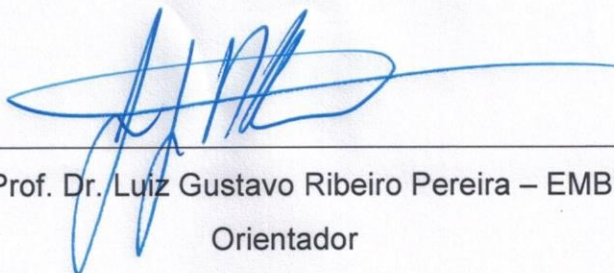
Título: "Detecção de estro em novilhas leiteiras com base em dados de cocho e bebedouros eletrônicos".

Autor (a): Frederico Correia Cairo

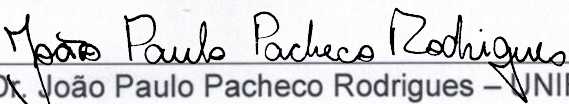
Orientador (a): Prof. Dr. Luiz Gustavo Ribeiro Pereira

Co-orientador (a): Prof. Dr. Thierry Ribeiro Tomich
Prof.^a Dr.^a Fernanda Samarini Machado

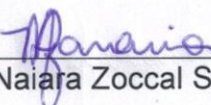
Aprovado como parte das exigências para obtenção do Título de MESTRE EM ZOOTECNIA, ÁREA DE CONCENTRAÇÃO: PRODUÇÃO DE RUMINANTES, pela Banca Examinadora:



Prof. Dr. Luiz Gustavo Ribeiro Pereira – EMBRAPA
Orientador



Prof. Dr. João Paulo Pacheco Rodrigues – UNIFESSPA



Dr.^a. Naiara Zoccal Saraiva - EMBRAPA

Data de realização: 25 de fevereiro de 2019.

“Toda coragem precisa
de um medo pra existir.
Uma estranha dependência
complicada de sentir.
A coragem de levantar
vem do medo de cair.

Use sempre a coragem
para se fortalecer.
E quando o medo surgir
não precisa se esconder.
Faça que seu próprio medo
tenha medo de você.”

(Bráulio Bessa)

Dedico este trabalho a Deus, por me proporcionar todas as manhãs um novo dia com saúde para que eu consiga realizar tudo que desejo.

Ao meu pai, Dylmar Ângelo Lima Cairo, por cumprir muito além do seu dever de pai, sem medir esforços para realizar todos meus sonhos.

À minha mãe, Cristina Maria Fernandes Correia Santos, por todo amor, carinho e cuidado, sempre me apoiando em todas as minhas decisões.

Ao meu irmão, Fernando Correia Cairo, pelo companheirismo de todos os momentos.

À minha irmã, Stefanie Marina Correia Cairo, por todo incentivo.

DEDICO

AGRADECIMENTOS

A realização desta dissertação marca o fim de mais uma conquista e como não se tem conquista sem ajuda, queria agradecer a todos aqueles, que contribuíram para a concretização desse trabalho.

A Deus e meus companheiros espirituais;

Ao Prof. Luiz Gustavo, pela orientação, dedicação, respeito e contribuição com seus conhecimentos à minha formação;

Ao João Dórea, pela atenção, tempo, prontidão e dedicação disponibilizada;

À Embrapa Gado de Leite (CNPGL) e à Universidade Estadual do Sudoeste da Bahia, que me proporcionou além de momentos de grande aprendizagem científica e profissional, bagagem para meu crescimento pessoal.

À Coordenação de aperfeiçoamento de pessoal de nível superior (CAPES), pela concessão da bolsa de estudos;

Aos meus pais, Dylmar Ângelo Lima Cairo e Cristina Maria Fernandes Correia Santos, pelo amor e educação que em meio a tantas dificuldades nunca permitiram que nada me faltasse, por sempre me incentivar e motivar a buscar meus sonhos, estando sempre ao meu lado, ensinando a viver a vida de modo correto e justo, traçar minhas metas em busca de objetivos cada vez maiores, por sempre me ampararem nos meus momentos mais difíceis, não me deixando jamais esmorecer.

Ao meu irmão, Fernando, pela amizade, cumplicidade, companheirismo e amor, por partilhar de todos os momentos da minha vida e entender, que Deus não nos enviou juntos por acaso. À minha irmã, Stefanie Marina, pelo respeito, amizade e amor. À minha avó, Maria Celeste, por ter me proporcionado tantos momentos inesquecíveis e que sempre farão parte de minha memória. Ao meu avô, Edy Correia (in memoriam), por ter permitido que o amor pelo campo pudesse continuar vivo em meu coração e poder torna-lo uma opção de profissão e futuro. Às minhas tias, Ana Maria (em memoriam) e Sônia, por terem sido exemplos de amor entre irmãos, ao campo, aos animais, e todas as palavras incentivo, minha eterna gratidão. A todos meus tios, tias, primos e primas.

Aos meus colegas de turma, pela convivência todos esses anos, Marceliana, Marina, Rebeka;

A Máylan por toda atenção, carinho e dedicação.

Aos amigos conquistados na Embrapa, Patrícia, Natalia, Eduardo e Júlio, por todos os almoços e encontros, que me fizeram me sentir mais próximo de casa, em especial à Paty, por todos nossos momentos juntos. À Vanessa por nossos cafés e sua atenção e preocupação. A João Paulo por tudo. A Rebeca, Ricardo, Daniele, Luana, Aline, Karen, Diego, Laís e todos os estagiários pelas horas vividas e pela troca de experiência.

Aos meus amigos do Vôlei: Robson, Leo, Thiago, Jean, Jholes, Fabio, Ilana, Geisiel, Lauro, por todos os momentos de descontração.

A todos, que contribuíram direta ou indiretamente para minha formação profissional, o meu muitíssimo obrigado!

BIOGRAFIA

FREDERICO CORREIA CAIRO, filho de Dylmar Ângelo Lima Cairo e Cristina Maria Fernandes Correia Santos, nasceu em 27 de fevereiro de 1993, em Vitória da Conquista, Bahia. Em 2012 iniciou o curso de Zootecnia na Universidade Estadual do Sudoeste da Bahia, finalizando o mesmo em 2016. Em 2017, iniciou o curso de Pós-Graduação em Zootecnia – Mestrado em Zootecnia, na Universidade Estadual do Sudoeste da Bahia – UESB, finalizando em 2019.

SUMÁRIO

	Página
LISTA DE FIGURAS	ix
LISTA DE TABELAS	x
LISTA DE ABREVIATURAS	xi
RESUMO	xii
ABSTRACT	xiv
I – REFERENCIAL TEÓRICO	1
1.1. Introdução	1
1.2. Tecnologia de precisão	3
1.3. Alterações e manifestações sexuais causadas pelo estro.....	5
1.4. Detecção do estro	5
1.5. Tecnologias para detecção de estro	6
1.5.1. Sistemas de detecção de estro com base em sensor de pressão	8
1.5.2. Sistemas de detecção de estro com base no monitoramento de atividade por acelerômetro	9
1.5.3. Câmera de vídeo para detecção de estro	11
1.5.4. Detecção de estro com base na gravação de vocalização	12
1.5.5. Detecção de estro por medição da concentração de progesterona no leite	12
1.6. Alterações no dia do estro em fêmeas bovinas	13
1.6.1. Alterações de Atividade	13
1.6.2. Alterações no Consumo	14
1.6.3. Alterações no Tempo de ruminação	14
1.6.4. Alterações nas Interações Sociais	15
1.7. Alterações de ambiência e manejo que afetam o comportamento estral.....	15
1.7.1. Ambiência e Estro	15
1.7.2. Nutrição e Estro	16
1.7.3. Protocolos hormonais e Estro	17
1.8. Modelos para tomada de decisão com base em Machine Learning	17

1.8.1 <i>Artificial Neural Network</i>	19
1.8.2 <i>Random Forest</i>	21
1.8.3 Regressão Logística	22
1.9. Referências	23
II – OBJETIVO	35
2.1. Objetivos gerais	35
2.2. Objetivos específicos	35
III – MATERIAL E MÉTODOS	37
IV – RESULTADO E DISCUSSÃO	44
V – CONCLUSÃO	51
VI – REFERÊNCIAS	52

LISTA DE FIGURAS

	Página
FIGURA 1. Exemplo de funcionamento de um tipo <i>de Rede Neural Artificial</i>	20
FIGURA 2. Processo de classificação baseado em <i>Random Forest</i>	22
FIGURA 3. Variação no consumo e comportamento alimentar de novilhas no dia do estro monitoradas por cochos e bebedouros eletrônicos.....	46

LISTA DE TABELAS

	Página
TABELA 1. Critérios para avaliação de métodos para detecção de estro em vacas leiteiras.....	8
TABELA 2. Composição nutricional (base MS) da dieta total (TMR) oferecida para novilhas nos ensaios experimentais.....	38
TABELA 3. Conjunto de covariáveis usadas em todas as abordagens preditivas	41
TABELA 4. Espaço de hiperparâmetros e critérios de busca utilizados na busca de redes neurais artificiais (RNA). Os hypermeters foram combinados para encontrar a melhor estrutura de RNA.....	42
TABELA 5. Espaço de hiperparâmetros e critérios de busca utilizados na busca da grade de Random Forest (RF).....	43
TABELA 6. Sensibilidade, especificidade, acurácia, valores preditos positivos (VPP), valores preditos negativos (VPN) para diferentes abordagens preditivas e conjuntos de covariáveis	48

LISTA DE ABREVIATURAS

ANN	<i>Artificial Neural Network</i>
Ca	Cálcio
CA	Consumo alimentar
CEUA	Comissão de Ética no Uso de Animais
CMS	Consumo de matéria seca
D	Dias
EE	Extrato etéreo
FDA	Fibra em detergente ácido
FDN	Fibra em detergente neutro
FN	Falso negativo
FP	Falso positivo
FSH	Hormônio folículo-estimulante
G	Gramas
GnRH	Hormônio liberador de gonadotrofina
H	Horas
Hol	Holandês
IA	Inseminação artificial
IATF	Inseminação artificial em tempo fixo
IEP	Intervalo entre partos
IGF1	Fator de crescimento semelhante à insulina tipo 1
Kg	Quilograma
L1	<i>Lasso regularization</i>
L2	<i>Ridge regularization</i>
LH	Hormônio Luteinizante
LOOCV	<i>Leave-One-Out Cross Validation</i>
M	Metros
MS	Matéria seca
N	Número

°C	Celsius
P	Fosforo
PB	Proteína Bruta
PGF2 α	Prostaglandina F2 α
PV	Peso vivo
RF	<i>Random Forest</i>
RL	Regressão Logística
Set	Conjunto de Covariáveis
T	Tempo
TC	Tempo no cocho
Tag	Brinco auricular com <i>transponder</i> eletrônico
TB	Tempo no bebedouro
TMR	Total Mixed Ration
TN	True negative
TP	True positive
VB	Visitas ao bebedouro
VC	Visitas ao cocho

RESUMO

Cairo, Frederico Correia. **Deteção de estro em novilhas leiteiras com base em dados de cochos e bebedouros eletrônicos**. Itapetinga, BA: UESB, 2019. 54 p. Dissertação. (Mestrado em Zootecnia, Área de Concentração em Produção de Ruminantes).*

RESUMO: A manifestação de estro causa redução no consumo e comportamento alimentar. Cochos e bebedouros eletrônicos que geram dados de forma automática, ainda não apresentam a funcionalidade de gerar alertas de estro. Os objetivos deste estudo foram: (i) avaliar as alterações causadas pelo estro nas variáveis de consumo e comportamento alimentar/hídrico obtidos em cochos e bebedouros eletrônicos e (ii) desenvolver e avaliar modelos para deteção e deteção antecipada do estro utilizando *Regressão Logística (RL)*, *Random Forest (RF)* e *Artificial Neural Network (ANN)*. Foram avaliados o consumo e o comportamento de ingestão de alimentos e água, e da manifestação de estro em dois ensaios com novilhas Holandês x Gir (Hol/Gir). A observação visual do estro foi realizada três vezes ao dia (7:00, 12:00 e 17:00 h) durante 30 minutos e os dados de consumo e comportamento alimentar/hídrico foram obtidos por sistema eletrônico de cochos e bebedouros. Foram observados 99 eventos de estro. Duas séries temporais de 7 dias foram coletadas, uma representada por 7 dias que antecedem o estro (ESTRO), e a outra por 7 dias sem evento de estro (ANESTRO). Com o intuito de desenvolver modelos capazes de detectar ESTRO ou ANESTRO com horas de antecedência, as séries temporais foram fracionadas em intervalos de 6 horas. Para cada intervalo de 6 horas o total de consumo de alimento (CA, % Matéria Natural), número de visitas no cocho de alimentos (VC), número de visitas no bebedouro (VA), tempo gasto consumindo alimento (TC) e tempo gasto bebendo água (TB) foram computados. Os modelos de deteção e deteção antecipada do estro foram estabelecidos utilizando três abordagens preditivas: *RL*; *ANN*; e *RF*. Doze conjuntos de covariáveis (Set) foram estabelecidos e os modelos testados para verificar a possibilidade de detectar o estro utilizando série temporal de 174 ou 24h (sets 1 e 4 ou 7 e 10), para verificar a acurácia e precisão na deteção antecipada do estro com 6 (sets 2,

5, 8 e 11) e 12 h (sets 3, 6, 9 e 12) de antecedência e com intuito de verificar a possibilidade de usar modelos que contemplassem somente os dados de comportamento alimentar/hídrico para detecção e detecção antecipada do estro (sets 4, 5, 6, 10, 11 e 12). Todas as variáveis apresentaram declínio significativo ($P < 0.05$) no dia do estro em comparação com os dias anteriores e com a série de anestro. Todos os modelos de detecção (0 a -24h e 0 a -174h) analisados com e sem a variável de consumo de alimentos foram precisos e acurados. A detecção antecipada do estro com 6 e 12 h de antecedência reduziu a acurácia, a sensibilidade e especificidade dos modelos avaliados. Modelos ANN (Set 2, 8 e 11), RF (Set 2, 5, 8 e 11) e RL (Set 11) apresentaram acurácia superior a 80%, indicando a possibilidade de detecção do estro com 06 horas de antecedência. Cochos e bebedouros eletrônicos permitem identificar as variações no consumo e comportamento alimentar causadas pelo estro em novilhas leiteiras. É possível identificar o estro de novilhas leiteiras com base em dados de ingestão e comportamento alimentar/hídrico obtidos em cochos e bebedouros eletrônicos. A detecção do estro pode ser realizada com base nos dados obtidos nas 24 h que antecedem o estro e a exclusão de dados de consumo e utilização somente de dados de comportamento alimentar/hídrico garantiram detecção acurada e precisa.

Palavras-chave: *machine learning*, modelagem, pecuária de precisão, detecção antecipada do estro, *random forest*, reprodução

ABSTRACT

Cairo, Frederico Correia. Detection of estrus in dairy heifers based on data from troughs and electronic drinking fountains. Itapetinga, BA: UESB, 2019. 54 p. Dissertation. (Master's Degree in Animal Husbandry, Area of Concentration in Ruminant Production). *

ABSTRACT: Estrus events can detrimentally affect feed intake and alter feeding and drinking behavior. Animal behavior and intake are collected by technologies such as electronic feeding gates, however, those technologies are not capable to generate estrus alert based on the collected data. The objectives of this study were: (i) to evaluate the effect of estrus on feed intake and animal behavior (feeding and drinking); and (ii) to develop and evaluate predictive approaches to detect estrus using data collected through electronic feeding gates. Feed intake, animal behavior, and estrus event were evaluated in two trials with Holandês x Gir (Hol / Gir) heifers. Visual observation was performed three times a day (7:00 a.m., 12:00 and 17:00 p.m.) for 30 minutes and the feed intake and animal behavior data were obtained through electronic feeding gates and electronic drinking stations. Ninety-nine events of estrus were observed. Two 7-day time series were collected: 1) 7 days with subsequent estrus event (ESTRO) and 2) 7 days without an estrus event (ANESTRO). In order to develop models capable of predicting ESTRO or ANESTRO in advance, the time series were fractionated in intervals of 6 hours. For each 6-hour interval, the total feed intake (FI, as-fed basis), number of visits in the bunk (VB), number of visits in the drinking station (VD), time spent eating (ET) and time spent drinking water (DT) were computed. Three predictive approaches were evaluated: Logistic Regression (LR); Artificial Neural Network (ANN); and Random Forest (RF). Twelve covariate sets (Set) were established: 1) using a time series of 174 or 24h (sets 1 and 4 or 7 and 10); 2) using time series to detect estrus 6 h (Sets 2, 5, 8 and 11) and 12 h (sets 3, 6, 9 and 12) in advance; 3) using time series that only included feeding and drinking behavior (sets 4, 5, 6, 10, 11 and 12). All variables presented a significant decline ($P < 0.05$) on estrus day compared to previous days and with the anestrus series. All predictive approaches (0 to -24 h and 0 to -174 h) analyzed with and without the

feed intake variable were accurate. The prediction of estrus with 6 and 12 hours of class reduced the accuracy and stability of the models. ANN models (Set 2, 8 and 11), RF (Set 2, 5, 8 and 11) and RL (Set 11) showed an accuracy of over 80%, indicating the possibility of predicting estrus at 06 hours in advance . Eletronic feeding and drinking stations collect valuable information related to animal behavior. It is possible to identify changes in feeding and drinking behavior and intake of dairy heifers during estrus event. Estrus detection can be performed based on the data collected 24 h prior to the estrus event. Feed intake was not crucial to increase accuracy on estrus detection when data on feeding and drinking behavior were available.

Key words: artificial neural network, machine learning, modeling, precision animal husbandry, estrus prediction, random forest

* Orientador: Luiz Gustavo Ribeiro Pereira, Dr. Embrapa Gado de Leite e Co-orientadores: João Ricardo Rebouças Dórea, Dr. University of Wisconsin e Mariana Magalhães Campos, Dra. Embrapa Gado de Leite.

I – REFERENCIAL TEÓRICO

1.1 INTRODUÇÃO

O aumento do número de animais, da produtividade e a redução de funcionários são mudanças que estão ocorrendo nos sistemas de produção de leite (Britt et al., 2018). Nesse cenário, o gerenciamento eficiente da reprodução tem efeito imediato na produção e lucratividade da atividade leiteira (Diskin e Sreenan, 2000). A identificação do estro é um dos principais fatores responsáveis pela eficiência reprodutiva (Röttgen et al., 2018). Para aumentar a eficiência de detecção do estro, o monitoramento automático do comportamento em rebanhos leiteiros vem ganhando importância nos últimos anos (Polsky et al., 2017), já que a observação visual permite índices de detecção variando de 50 a 90% (Roelofs et al., 2010).

O padrão de comportamento manifestado por fêmeas bovinas durante o estro envolve alterações de atividade (Kerbrat e Disenhaus, 2004), como também no comportamento ingestivo (Pahl et al., 2015; Reith et al. 2014). Segundo Palmer et al. (2010), o período de duração e intensidade do estro são características, que podem ser afetadas negativamente com o aumento da idade, produção de leite e fatores ambientais. Os estudos envolvendo avaliação das variações, que ocorrem devido ao estro são importantes para o desenvolvimento de algoritmos para identificação de variações comportamentais relacionadas ao estro que possam ser a base para acionar alertas para a tomada de decisão.

A necessidade de aumentar a eficiência de identificação do tempo ideal para inseminação desencadeou o desenvolvimento de dispositivos automáticos de detecção de estro (Rottgen et al., 2018). As tecnologias de precisão que permitem o monitoramento contínuo do comportamento dos animais são potenciais alternativas para melhorar os índices reprodutivos nas propriedades leiteiras (Polsky et al., 2017). O aumento relativo da atividade física do animal permite captar alterações e fornecer indicadores eficientes para detecção do estro (Jónsson et al., 2011). A sensibilidade e especificidade dos dispositivos automatizados podem ser aumentadas pela incorporação de variáveis relacionadas direta ou indiretamente ao comportamento manifestado durante o estro (Rottgen et al., 2018). Para determinar a precisão da tecnologia ou

sensor específico para detecção do estro, é necessário que haja a comparação dos eventos do estro (identificados pelo algoritmo da tecnologia) com padrão ouro, podendo este ser: observação visual, ultrassonografia, níveis de progesterona no sangue ou no leite ou combinação destes (Dolecheck et al., 2015).

O aumento da atividade no dia do estro contribui para que ocorram alterações no comportamento alimentar das fêmeas bovinas (Reith et al., 2017), e essa variação pode ser detectada pelo monitoramento contínuo do consumo. Segundo Chizzotti et al. (2015) cochos e bebedouros eletrônicos têm permitido mensurar continuamente o consumo e o comportamento alimentar. Entretanto, esses dispositivos ainda não têm a funcionalidade de identificação de estro.

A quantidade de dados gerados pelos sistemas automáticos tem aumentado ao longo dos anos (Wolfger et al., 2017). Assim, a possibilidade de integrar dados de diferentes sensores como sistemas de registro animal (software contendo a identificação de vacas, produção de leite, consumo, peso corporal e assim por diante) (Dolecheck et al., 2016; Borchers et al., 2017) pode ser o caminho para o desenvolvimento de mecanismos de tomadas de decisão precisos e precoces.

A adoção de métodos de *Machine Learning*, como *Neural Network* e *Random Forest*, podem permitir o desenvolvimento de modelos de tomada de decisão com base em dados gerados por sensores instalados em sistemas de produção. Os métodos de *Neural Networks* imitam a estrutura e a função do cérebro humano, simulando a inteligência humana, com capacidade de modelar relações complexas entre variáveis, tais como não-linearidades e interações (Gianola et al., 2011), aprendendo de forma independente e rápida, adaptando-se continuamente e aplicando o raciocínio indutivo para processar o conhecimento (Zahedi, 1991; Krieter et al., 2006). Nas ciências animais, as redes neurais foram utilizadas para prever o parto (Borchers et al., 2017), cetose subclínica (Ehret et al., 2015), estro (Dolecheck et al., 2015) e consumo de matéria seca (Dorea et al., 2018).

A possibilidade de detecção e detecção antecipada do estro com base nas alterações de consumo e comportamento alimentar é pouco estudada, assim, as hipóteses do presente trabalho são: *i*) cochos e bebedouros eletrônicos permitem identificar as variações no consumo e comportamento alimentar causadas pelo estro em novilhas leiteiras e, *ii*) modelos desenvolvidos por Regressão Logística, *Artificial Neural Network*, e *Random Forest* são capazes de detectar com antecedência (com 6 ou 12 h de antecedência) e detectar o estro de novilhas leiteiras com base nas variáveis

geradas por cochos e bebedouros eletrônicos, e: *iii*) dados de séries temporais de 24 h são suficientes para detecção e detecção antecipada do estro, não sendo necessária a utilização de dados de uma semana (174 h); *iv*) é possível detectar e detectar com antecedência o estro somente com dados de comportamento alimentar (não utilizando dados de consumo, variável geralmente mais cara para ser obtida).

Os objetivos deste estudo foram: (1) avaliar as alterações causadas pelo estro em novilhas leiteiras nas variáveis de consumo e comportamento alimentar/hídrico obtidos em cochos e bebedouros eletrônicos e (2) desenvolver e avaliar modelos para detecção e detecção antecipada (6 e 12 h de antecedência) do estro com base nos dados gerados por cochos e bebedouros eletrônicos utilizando Regressão Logística, *Artificial Neural Network*, e *Random Forest*.

1.2 TECNOLOGIAS DE PRECISÃO

Tecnologias inovadoras e biotecnologias contribuem significativamente para o avanço da produção animal, permitindo a identificação da variabilidade animal e o desenvolvimento de produtos, processos e serviços para aplicação do conceito de pecuária de precisão nas fazendas leiteiras (Leão et al., 2015). O monitoramento e o gerenciamento dos animais tornaram-se mais desafiadores e complexos, devido à expansão dos tamanhos dos rebanhos, exigindo maior capacidade de gerenciamento (Edwards et al., 2015; Bewley, 2016). Para suprir o desafio de monitorar maior número de animais, tecnologias de coleta de dados individuais dos animais vêm sendo desenvolvidas com o intuito de auxiliar a tomada de decisão.

A integração entre tecnologias de precisão com o campo deve envolver a atuação de profissionais de diferentes áreas, como: pesquisadores, agrônomos, veterinários, zootecnistas, consultores, engenheiros, matemáticos e técnicos de equipamentos agrícolas. Algumas barreiras, como a falta de infra-estrutura (conectividade) ou habilidades específicas (conhecimento de análise de software ou gerenciamento e integração de dados), podem retardar a adoção das tecnologias de precisão (Jago et al., 2013; Eastwood et al., 2017). Com isso, a relação entre técnicos e produtores pode garantir tomada de decisão amparada pela análise dos dados gerados pelas tecnologias que, por sua vez, tem que atender as demandas do sistema de produção, garantindo a redução de falhas no manejo e gerenciamento, aumentando os índices produtivos e a margem de lucro.

As tecnologias de precisão utilizadas atualmente para o monitoramento do comportamento animal envolvem a avaliação das mudanças na atividade geral, com base em dados de sensores, permitindo a identificação precoce de problemas de saúde (Beer et al., 2016), do estro (Dolecheck et al., 2016), do comportamento deitado, em pé e andando (Ledgerwood et al., 2010), do comportamento de pastejo (Nielsen, 2013), o monitoramento de problemas podais (Beer et al., 2016) e para a indicação da posição em tempo real de cada vaca (Wolfger et al., 2017). Os dispositivos já disponíveis no mercado e os que estão sendo desenvolvidos apresentam potencial para melhorar o monitoramento animal em tempo real (Nielsen et al., 2018).

Tecnologias de precisão também têm sido propostas para mensurar consumo de alimentos e água, comportamento alimentar, batimento cardíaco, frequência respiratória, temperatura da superfície corporal, pH ruminal e escore corporal (Carvalho et al., 2014). A combinação dessas tecnologias pode contribuir para melhorar a precisão na detecção de anormalidades e estro.

Gerar dados de forma automática e precisa está cada vez mais fácil e barato, porém, é necessário transformar dados em informações que possam ser utilizadas para tomadas de decisão acertadas. Esses dados devem ser coletados por meio de tecnologias validadas e incorporados a modelos e algoritmos, combinando o conhecimento de campo e dados de pesquisa. Para o êxito com a utilização de tecnologias de precisão, os agricultores, técnicos e equipe de apoio devem aprender a interpretar as informações corretamente e, com essas informações, podem implementar o manejo adequado do rebanho e as ações corretivas necessárias para melhorias de processo (King et al., 2018)

Gargiulo et al. (2018) identificaram as tecnologias com maior potencial de adoção nos próximos 10 anos entre produtores de leite da Austrália: sistemas automáticos de detecção de estro (média 80%), portões automáticos para o direcionamento de animais (média 74%) e ferramentas automatizadas de detecção de mastite (média 63%). É necessário o avanço do conhecimento sobre tecnologias disponíveis para o desenvolvimento de novos modelos para tomada de decisão com foco no aumento da eficiência das fazendas leiteiras.

1.3 ALTERAÇÕES E MANIFESTAÇÕES SEXUAIS CAUSADAS PELO ESTRO

O estro envolve a manifestação externa dos eventos fisiológicos relacionados à ovulação, garantindo que a fêmea seja copulada próximo à ovulação, permitindo com isso, a fecundação (Roelofs et al., 2010). Segundo Aungier et al. (2015), as funções ovarianas (desenvolvimento folicular, ovulação, luteinização e luteólise) são reguladas por hormônios endócrinos secretados pelo hipotálamo (hormônio liberador de gonadotropina (GnRH)), hipófise anterior (FSH e LH), ovários (progesterona, estradiol e inibina) e o útero (prostaglandina F_{2α} - PGF_{2α}). Elevadas concentrações de estradiol secretadas pelo folículo pré-ovulatório promovem aumento do GnRH e permitem a expressão do estro comportamental e a liberação de LH para causar a ovulação (Reith et al., 2017). O estradiol também exerce influência sobre o sistema genital, tornando-o edematoso, tônico e altamente secretor, em especial as glândulas cervicais, levando à liberação do muco característico do estro (Roelofs et al., 2010).

1.4 DETECÇÃO DO ESTRO

A detecção do estro é um dos fatores mais importantes, que afeta a eficiência reprodutiva em bovinos de leite, especialmente em fazendas que usam inseminação artificial (Dolecheck et al., 2015). O manejo da reprodução afeta diretamente o período voluntário de espera, o intervalo entre partos (IEP) e a produção de leite, o que impacta no lucro da propriedade. Os maiores desafios da detecção do estro em fazendas incluem: vacas com condições anovulatórias (Wiltbank et al., 2002); atenuação da duração do comportamento do estro associado ao aumento da produção de leite perto do estro, resultando em períodos mais curtos de tempo para detectar visualmente o comportamento do estro (Lopez et al., 2004); ovulações silenciosas (Valenza et al., 2012); e reduzida expressão de estro devido a sistemas de alojamento em confinamento (Palmer et al., 2010) com piso de concreto (Britt et al., 1986).

Os métodos tradicionais de detecção de estro incluem a observação do período entre a primeira e a última vez que a vaca é montada também conhecido como estro em pé e sinais secundários, como a montagem de outras vacas, inquietação, muco vaginal claro e vulva inchada (Roelofs et al., 2010). À medida que aumenta o tamanho do rebanho, a observação visual das vacas pode apresentar dificuldades operacionais,

resultando em estro não observado e perdas econômicas (Reith et al., 2017). De acordo com Roelofs et al. (2010), a eficiência da detecção de estro baseada na observação varia de 50% a 90%. Embora o desempenho reprodutivo ruim cause uma maior taxa de descarte, poucas vacas são descritas como inférteis, pois cerca de 90% dos fatores para baixas taxas de detecção podem ser atribuídos ao manejo e 10% à vaca (Diskin e Sreenan, 2000).

A expressão do estro também pode ser influenciada por vários fatores, tais como: número de dias pós-parto, número de lactações, produção de leite, saúde, ambiente, tamanho do rebanho, dentre outros (Roelofs et al., 2010). A duração e intensidade no comportamento de estro também podem ser influenciadas pelo número de fêmeas em estro simultâneo (Van Vliet e Van Eerdenburg, 1996). Para caracterizar a relação entre produção de leite e duração do estro, Lopez et al. (2004) observaram que vacas com produção acima de 55 kg de leite por dia têm 2,8 horas de duração do comportamento sexual, e vacas com produção média de 25 kg de leite ao dia, têm duração de 14,7 horas de comportamento estral. Wiltbank et al. (2006) encontraram coeficiente de correlação de $r = -0,51$ entre duração do estro e produção de leite.

O monitoramento constante da atividade sexual nem sempre pode ser feito devido às rotinas das propriedades. Durante a alimentação, e antes ou após a ordenha da manhã podem ser identificados 86% dos comportamentos de estro, quando os animais são monitorados continuamente (Van Eerdenburg et al., 1996). No entanto, Fonseca (2017) reportou que quando a observação de estro é feita por 30 minutos, em dois períodos do dia, a taxa de identificação dos animais em estro é de 63%, quando comparados aos monitorados continuamente. Assim, há uma tendência de utilização de métodos baseados em tecnologias para monitoramento contínuo e automático para a detecção do estro em gado leiteiro.

1.5 TECNOLOGIAS PARA DETECÇÃO DE ESTRO

A necessidade de adoção de método confiável para identificar o momento ideal da inseminação em bovinos leiteiros desencadeou o desenvolvimento de dispositivos automáticos para detecção de estro (Volker et al., 2018). Para Dolecheck et al. (2015), as tecnologias automatizadas de detecção de estro são alternativas disponíveis para suplementar ou substituir a detecção visual de estro. Parâmetros para a detecção, normalmente, incluem a quantificação de eventos de monta entre os animais, nível de

atividade, eventos de ruminção, concentrações de progesterona no sangue ou leite, tempo de alimentação, temperatura corporal e vocalização (Senger, 1994; Saint-Dizier e Chastant-Maillard, 2012; Fricke et al., 2014; Volker et al., 2018).

Novas tecnologias de precisão permitem o monitoramento contínuo do comportamento dos animais que, por sua vez, pode ser usado para melhorar o manejo reprodutivo (Polsky et al., 2017), identificando o estro com a maior precisão possível. Vários acelerômetros e algoritmos de processamento de dados foram desenvolvidos para detectar mudanças relevantes na atividade (Leroy et al., 2017). Segundo Dolecheck et al. (2015), a precisão da detecção de estro depende de três fatores: (1) quão fortemente os parâmetros medidos estão associados ao estro, (2) com que precisão a tecnologia está medindo esses parâmetros e (3) se o algoritmo do fabricante de tecnologia é preciso em emitir alerta de estro úteis.

O conhecimento detalhado e abrangente, considerando os fatores relacionados à fêmea bovina, como ambiente e manejo, além dos sinais comportamentais do estro, é crucial para o refinamento de tecnologias totalmente automatizadas para identificação de vacas em estro (Reith et al., 2017). O foco principal é o monitoramento de atividades para detectar o aumento significativo das mesmas que ocorre durante o proestro. Uma combinação de monitoramento de atividades e vários outros métodos pode levar a taxas de detecção de estro aceitáveis, e assim, otimizar o manejo reprodutivo em fazendas leiteiras.

Para determinar a acurácia e a precisão de dispositivos de detecção de estro, os eventos de estro identificados (um conjunto de critérios usados para determinar o estro) são comparados com o chamado “padrão ouro”, ou seja, a observação visual do estro, acompanhamento com ultrassonografia, dosagem dos níveis de progesterona no sangue ou no leite ou a combinação desses. A confiabilidade do método para a detecção do estro pode ser mensurada com base na sensibilidade e especificidade. A sensibilidade expressa a porcentagem de eventos de estro detectados corretamente, enquanto a especificidade é a probabilidade de um alerta ausente quando o evento não ocorre (Reith et al., 2017). Eventos de estro estritamente identificados são classificados como verdadeiros positivos (TP). Eventos de estro não alertados levam a resultados falso-negativos (FN). Alertas fora dos eventos de estro são considerados verdadeiros negativos (TN), e eventos não-estro alertados são denotados como falso-positivos (FP). A porcentagem de alertas de falso estro em relação ao número de eventos de estro detectados é indicada pela taxa de erro 1 (Firk et al., 2002), expressos na tabela 1.

Muitas vezes, há contradição entre a sensibilidade e a especificidade, pois o aumento na sensibilidade provoca declínio no segundo parâmetro.

Tabela 1. Critérios para avaliação de métodos para detecção de estro em vacas leiteiras.

Critério	
Taxa de detecção / eficiência / sensibilidade	$TP / (TP + FN) \times 100$
Especificidade	$TN / (TN + FP) \times 100$
Taxa de erro / taxa de resultados falso-positivos	$FP / (TP + FP) \times 100$

TP = verdadeiro positivo; FN = falso negativo; FP = falso positivo; TN = verdadeiro negativo.

Até o momento, a maioria das tecnologias para identificação de vacas em estro baseia-se na medição automatizada de atividades (Madureira et al., 2015; Dolecheck et al., 2016). Este sistema é repetidamente considerado adequado para a detecção de estro, tornando-o lucrativo para a maioria das explorações leiteiras (Rutten et al., 2014). Alguns trabalhos que envolveram a avaliação dos benefícios econômicos propiciado pelos dispositivos automáticos de detecção de estro mostraram aumento na sensibilidade (80%) em comparação com à taxa de detecção pela observação visual (50%) (Reith et al., 2017).

A combinação de variáveis para o desenvolvimento de modelos de detecção de estro pode melhorar a sensibilidade para a detecção de estro. Os principais métodos disponíveis para auxiliar a detecção de estro são: observação durante vários períodos de tempo ao dia por uma pessoa capacitada, sistemas de detecção de pressão, pedômetro, acelerômetros, câmeras de vídeo, vocalização, níveis de progesterona no leite. Firk et al. (2002) sugeriu que o objetivo da combinação dessas variáveis deveria alcançar valores de referência com eficiência de detecção maior que 90% e uma taxa de erro menor que 20%.

1.5.1 SISTEMA DE DETECÇÃO DE ESTRO COM BASE EM SENSOR DE PRESSÃO

O HeatWatch® (DDx Inc., Boulder, CO, EUA) (Walker et al., 1996; At-Taras e Spahr, 2001) ou DEC® (IMV Technologies, L'Aigle, França) (Saumande, 2002) são dispositivos eletrônicos sensíveis à pressão e baseiam-se na detecção do início e duração das montarias por vacas em estro. Um transmissor sensível à pressão é acoplado à bolsa e colado na região sacral dos animais (Saint-Dizier & Chastant-Maillard, 2012). A vaca, ao entrar em estro, deixa-se montar pelas companheiras ou

pelo rufião. Esses animais, ao realizarem a monta, acionarão, pela pressão, o transmissor que emite onda captada por antena (receptor), que transmite sinal para computador com software de gerenciamento (At-Taras e Spahr, 2001). O início do estro é confirmado pela primeira ativação do sensor (Lopez et al., 2004). Esse método se mostra bastante preciso, visto que o sistema funciona durante 24 horas por dia, evitando perdas na detecção do estro que se manifestam no período noturno (Porto-Filho et al., 2005).

Houve divergências entre estudos relacionados ao uso dos sistemas sensíveis à pressão. Em dois ensaios diferentes, At-Taras e Spahr (2001) encontraram uma eficiência média de 79% para a detecção baseada no HeatWatch® em comparação com 54,5% fornecidos pela observação visual de vacas. Peralta et al. (2005) relataram eficiências semelhantes – 48,0% identificadas pelo sistema e 49,3% por observação visual. Saumande (2002), utilizando o sistema DEC® obteve eficiência menor em relação ao sistema baseado em observação visual (35,4% vs. 68%). O potencial dos sistemas sensíveis à pressão é afetado pelas condições de instalação (Palmer et al., 2010), tipo de piso (Britt et al., 1986), clima (Peralta et al., 2005) e dificuldades em manter os sensores na posição adequada (Diskin e Sreenan, 2000).

1.5.2 SISTEMAS DE DETECÇÃO DE ESTRO COM BASE NO MONITORAMENTO DE ATIVIDADES POR ACELERÔMETRO

Monitores de atividade utilizam alterações comportamentais na atividade física e inquietação exibidos durante o estro para detectar o estro (Roelofs et al., 2010) e são sugeridos para prever o tempo de ovulação (Stevenson et al., 2014; Madureira et al., 2015; Polsky et al., 2017). Pedômetros registram o número de passos dados por unidade de tempo como indicador de atividade de caminhada, variável alterada durante o proestro e o estro de vacas leiteiras (López-Gatiús et al., 2005; Roelofs et al., 2005; Yániz et al., 2006). Mais precisamente, as vacas que entram em estro são identificadas pelo aumento na locomoção acima do valor médio de atividade registrado nos dias anteriores (Roelofs et al., 2005; Yániz et al., 2006). Madureira et al. (2015) relataram que o aumento no padrão de atividade utilizando pedômetro foi de $334,3 \pm 155,7\%$ passos e atingiu valor preditivo positivo para detecção de estro de 85,5% em vacas da raça Holandês. No entanto, Holman et al. (2011) relataram menor sensibilidade na

utilização do pedômetro comparado (63,3%) a observação visual (68,8%) do estro em vacas e novilhas.

Foi demonstrado que monitores de atividade automatizados melhoram as taxas de detecção de estro e concepção em comparação à detecção visual (Peralta et al., 2005) e podem ser integrados em protocolos de inseminação artificial em tempo fixo (IATF), programados para selecionar animais quando eles entram em estro (Burnett et al., 2017). Yoshioka & Tanimoto (2010) em estudo com pedômetro e sua relação com as taxas de concepção avaliaram 20 vacas *Japanese Black* com pedômetro radiotelemétrico e 24 vacas no grupo controle (detecção visual de estro durante 30 minutos, três vezes ao dia). Constataram que os animais do grupo que utilizou o pedômetro obtiveram alta taxa de concepção (90,0%) em comparação aos do grupo controle (58,4%). Salientaram que o método eletrônico foi excelente para detecção do estro e eficaz na avaliação do tempo ideal da ovulação.

Brehme et al. (2008) testaram outro tipo de pedômetro, o ALT, que possui três parâmetros para mensuração: atividade, tempo de repouso e temperatura corporal. O pedômetro ALT foi comparado com o sistema medidor de atividade física situado no pescoço (ALPRO) e a detecção visual de estro em 11 vacas leiteiras no período de sete meses. O pedômetro ALT registrou 40, o ALPRO 23 e a detecção visual 17 ciclos estrais.

Os medidores de atividade baseados em acelerômetros geralmente são acoplados aos colares (Madureira et al., 2015; Gaillard et al., 2016) e medem acelerações horizontais contínuas relacionadas aos movimentos ascendentes da cabeça e pescoço da vaca durante o comportamento de andar e montar (Reith et al., 2014). Os dados gerados representam escore de atividade médio (Silper et al., 2015), que pode ser armazenado em intervalos de uma (Gaillard et al., 2016) ou duas horas (Reith et al., 2014; Madureira et al., 2015). Para separar a atividade diária da vaca das atividades associadas ao comportamento estral, são usados algoritmos baseados nos desvios entre dados atuais e históricos. Os dados são captados por antena e transferidos automaticamente para o software de gerenciamento de rebanho, fornecendo listas e gráficos para controlar o status reprodutivo e de saúde de cada vaca (Reith et al., 2014).

Aungier et al. (2015) mostraram que o início do comportamento relacionado ao estro acontece seis horas antes do início do aumento de atividade registrado pelo sistema Heatime® (SCR Engineers Ltd, Netanya, Israel) e concluíram que 3 horas após o início do aumento de atividade, o sistema alertou o estro em 90% das vacas e

identificou incorretamente 17% do número total de estro. Valenza et al. (2012) verificaram que a porcentagem de vacas detectadas em estro não diferiu entre o sistema baseado em acelerômetro e os detectores de estro com base em termostatos (71% versus 66%, respectivamente). Assim, os sistemas baseados em acelerômetros são descritos como úteis para detectar o estro e melhorar a fertilidade em bovinos leiteiros (Valenza et al., 2012). A tecnologia está comercialmente disponível para medição de atividade ou em combinação com características de ruminação (Reith et al., 2014).

1.5.3 CÂMERA DE VÍDEO PARA DETECÇÃO DE ESTRO

Esse método tem sido utilizado com a finalidade de identificar o estro sem a presença de observador no local de agrupamento dos animais. A câmera registra o momento da monta. A grande dificuldade desse método é relacionada a necessidade de assistir os vídeos diariamente, bem como o alto custo de implantação (Saint-Dizier & Chastant-Maillard, 2012). Bruyère et al. (2012) reportaram eficiência de detecção baseada em gravação de vídeo maior em comparação com a obtida por observação visual clássica (80% vs. 68,6%).

Alawneh et al. (2006) realizaram estudo para avaliar a sensibilidade, especificidade, valores preditivos e acurácia de detecção de estro, utilizando métodos detectores de monta (pintura da cauda; câmera de vídeo) associados com a observação visual e uso de tinta na cauda (Kamar®), com 480 vacas criadas a pasto. Um grupo (n=240) foi equipado com a tinta na cauda e também monitorado com câmeras de vídeo, enquanto o grupo do controle (n=240) foi monitorado usando tinta na cauda e observações visuais. Comparado com o grupo controle, a detecção de estro utilizando a tinta na cauda e a câmera de vídeo resultaram em maior sensibilidade (85% versus 78%, $P = 0,006$), especificidade (99,6% versus 98,0%, $P < 0,001$), valor preditivo positivo (88% versus 51%, $P < 0,001$) e precisão (99,0% versus 98,0%, $P < 0,001$). A utilização da câmera de vídeo aumentou significativamente a porcentagem de vacas gestantes durante o período de acasalamento (Alawneh et al., 2006).

1.5.4 DETECÇÃO DE ESTRO COM BASE NA GRAVAÇÃO DE VOCALIZAÇÃO

A taxa de vocalização é variável comportamental promissora para a detecção de estro (Schön et al., 2007; Dreschel et al., 2014). Em estudos prévios, Dreschel et al. (2014) demonstraram que as taxas de vocalização aumentam em novilhas em estro tanto em baias individuais quanto em alojamento em grupo. Vocalizações são gravadas continuamente por um microfone acoplado ao arreio colocado no animal. As gravações são transferidas para receptor estacionário via transmissor. Pelo uso do algoritmo disponível, as janelas de sinais são geradas a partir da gravação do som e somente aquelas com médias superiores a limiar pré-definido são consideradas para a detecção do estro. Volker et al. (2018) compararam as vocalizações de 12 novilhas Holandês em estro natural nos dias que antecede o estro (d -1), dia do estro (d 0) e um dia depois do estro (d +1). No d 0 encontraram vocalizações médias de 9,6 (\pm 3,8), no dia d -1, 110,3 (\pm 41,2), e 7,5 (\pm 2,8) em d +1, confirmando que o padrão de atividade vocal apresenta potencial para elaboração de dispositivos automatizados para detecção de estro.

1.5.5 DETECÇÃO DE ESTRO POR MEDIÇÃO DA CONCENTRAÇÃO DE PROGESTERONA NO LEITE

Como a concentração sanguínea de progesterona está intimamente associada à sua concentração no leite, a análise de progesterona de amostras de leite representativas pode ser usada para determinar o status reprodutivo da vaca leiteira (Reith et al., 2017). O modelo evoluiu usando três situações (anestro pós-parto, estro ou prenhez) e simulando os dados, baseados no biossensor eletroquímico para determinação de níveis de progesterona no leite, e está apto a distinguir os estados reprodutivos (Madureira et al., 2015). O desenvolvimento de sistemas de monitoramento automático em linha e em tempo real, como o Herd Navigator® (DeLaval, Tumba, Suécia) substituem a coleta manual de informações sobre progesterona (Reith et al., 2017). As amostras tiradas durante a ordenha são coletadas em unidade de entrada de amostra e transferidas automaticamente para a unidade de análise conectada ao computador.

Friggens et al. (2008) testaram o modelo e avaliaram o status reprodutivo em 55 medições de progesterona no leite em 578 lactações de 380 vacas. Foram identificados dois tipos de estros: (1) estro confirmado (em que a IA resultou em uma confirmação de

gestação, n=121); e (2) estro ratificado (perfil de progesterona maior que 1 ng/mL, n=679). O modelo detectou 99,2% dos estros confirmados. Usando estros ratificados, a sensibilidade do modelo foi de 93,3% e especificidade de 93,7% para a detecção de estro.

1.6 ALTERAÇÕES NO DIA DO ESTRO EM FÊMEAS BOVINAS

1.6.1 ALTERAÇÕES DE ATIVIDADE

Os padrões de comportamento alterados durante o estro são sinais secundários entre os bovinos e indicam atividade fisiológica aumentada envolvendo a busca de parceiro de acasalamento compatível (Kerbrat & Disenhaus, 2004). A atividade aumentada acentuadamente em vacas que se aproximam do estro foi relatada por vários pesquisadores (Silper et al., 2015; Gaillard et al., 2016; Reith et al., 2017), indicando uma precisão confiável de inquietação sexual.

Kerbrat & Disenhaus (2004) realizaram estudo comparando o dia anterior ao estro com o dia do estro e relataram que o tempo de caminhada aumentou em 342%, variando de 21% a 913% no dia estral de cada vaca, com duração de 8 h antes a 5 h após o início do estro. A atividade medida obtida por acelerômetro alocado em colares evidenciou aumento de 17 ± 1 movimentos / hora no momento do estro comparado aos 5 dias antes do dia do estro, podendo ser explicado pelo comportamento de monta no dia estro. (Gaillard et al., 2016).

Segundo Reith et al. (2017), a duração dos episódios de atividade em torno do estro variam entre 11 e 19,1 h. Vacas multíparas expressaram menor intensidade (Reith et al., 2014) e pico de atividade (Madureira et al., 2015), como previamente demonstrado por López-Gatius et al. (2005), que calcularam que cada lactação adicional reduziu 21,4% a locomoção de vacas no cio.

Efeitos negativos da alta produção de leite foram relatados por Yániz et al. (2006) e López-Gatius et al. (2005), que observaram redução de 1,6% na atividade de caminhada quando a produção de leite aumentou em 1 kg. Reith et al. (2014) encontraram maior agitação em vacas estrais entre 2 h e 8 h. Dessa forma, vacas que expressam o estro à noite e nas primeiras horas da manhã podem não ter o cio detectado quando apenas a observação visual do estro é utilizada.

1.6.2 ALTERAÇÕES NO CONSUMO ALIMENTAR E HÍDRICO

O estro altera o consumo e o comportamento alimentar. Os efeitos do estro no comportamento alimentar variam entre estudos. Lukas et al. (2008) descreveram aumento de 0,61 kg / dia no consumo de matéria seca (CMS) durante o estro, Reith et al. (2017) reportaram o declínio de 14,6% em média e De Silva et al. (1981) não encontraram nenhum efeito no CMS. Pahl et al. (2015) identificaram o declínio na atividade de alimentação no dia anterior à inseminação e no dia da inseminação, reduzindo o tempo disponível para o consumo da dieta. O aumento na atividade das vacas é considerado responsável pela redução no tempo em ócio e no tempo de cocho (Hurnik et al., 1975).

Diskin & Sreenan, (2000) verificaram que durante o estro, as vacas mudaram o comportamento alimentar e a produção de leite, com redução no tempo de alimentação e na produção de leite. Já Pahl et al. (2015) não encontraram redução na produção de leite mesmo com diminuição no consumo e no tempo de ruminação. Os estudos envolvendo a identificação das variações do comportamento ingestivo em cochos e bebedouros eletrônicos associados ao estro são escassos. O conhecimento detalhado e abrangente, considerando os fatores relacionados à dinâmica de consumo, dos sinais comportamentais no dia do estro são importantes e podem definir se é possível ou não adotar a utilização desses dispositivos (cochos e bebedouros eletrônicos) para a detecção e detecção antecipada (6 e 12 h de antecedência) de estro, conferindo nova funcionalidade para esses equipamentos.

Os cochos eletrônicos permitem avaliar com precisão variáveis comportamentais da dinâmica do consumo e gerar dados, como: quantidade de alimento consumido, tempo de consumo, número e tempo de visitas ao cocho (Chizzoti et al., 2015).

1.6.3 ALTERAÇÕES NO TEMPO DE RUMINAÇÃO

A ingestão de matéria seca é influenciada pelo estro, e com isso, geralmente o tempo de ruminação e ócio também são alterados (Dolecheck et al., 2015). No período entre 22 h e 4 h, a atividade de ruminação é elevada, tanto em vacas (Schirrmann et al., 2012) quanto em bezerros (Rodrigues et al., 2018). Assim, o período da noite é o mais adequado para detectar mudanças comportamentais que impactam o tempo de ruminação. Reith et al. (2014) analisaram dados de atividade e tempo de ruminação que

podem ser registrados de forma exata e automática em uma base diária para cada vaca com sistema de sensor baseado em microfone. Inesperadamente, o número de vacas com atividade aumentada no estro foi menor que o identificado pelo tempo de ruminação (76,5% v. 86,2%), sugerindo que a duração da ruminação pode ser uma variável com capacidade de permitir a detecção de estro de forma mais acurada e precisa em comparação com o escore de atividade (Reith et al., 2014).

1.6.4 ALTERAÇÕES NAS INTERAÇÕES SOCIAIS

No período do estro, as vacas são mais motivadas a envolver-se em interações agonísticas e sociais do que durante o diestro. Reith et al. (2017) observaram que o confronto cabeça-com-cabeça representou 73,4% dos comportamentos agonísticos mais frequentes. Fonseca (2017) reportou que os principais comportamentos sociais entre novilhas F1 (Holandês x Gir) foram tentar montar as companheiras do rebanho, cheirar a vulva, lambar alguma parte do corpo de outra novilha, seguir as outras companheiras do rebanho e permanência na posição cabeça com cabeça com outra novilha, sendo esse último, o comportamento mais frequente. Geralmente, interações sociais e agonísticas são afetadas principalmente pela densidade populacional (Reith et al., 2017). Diskin e Sreenan (2000) descobriram que a superlotação reduzia a exibição de sinais de estro por não haver espaço adequado para a locomoção e repouso dos animais. As vacas recebem estímulo sexual pelo grupo de animais em estro, e esse comportamento é fundamental para manifestação e detecção do estro.

1.7 ALTERAÇÕES DE AMBIÊNCIA E MANEJO QUE AFETAM O COMPORTAMENTO ESTRAL

1.7.1 AMBIÊNCIA E ESTRO

Fatores ambientais como chuva, velocidade do vento, temperatura e umidade ambiente podem afetar significativamente a expressão do comportamento do estro (Roelofs et al., 2010). A zona termoneutra do gado leiteiro varia de 5 °C a 25 °C quando se considera apenas a temperatura do bulbo seco (Polsky et al., 2017). O estresse térmico é definido como a magnitude das forças de alta temperatura, externas ao corpo, que fazem com que o animal exceda sua zona termoneutra e induzam mecanismos de

enfrentamento para evitar a disfunção fisiológica (Kadzere et al., 2002). Vacas com estresse calórico reduziram a produção de leite, o CMS e a atividade física (De Rensis e Scaramuzzi, 2003; West, 2003; Schütz et al., 2008). A capacidade reprodutiva do gado leiteiro diminui à medida que o estresse térmico atrapalha o desenvolvimento folicular, a esteroidogênese, a qualidade do oócito e o desenvolvimento do embrião (Pereira et al., 2015). Sakatani et al. (2012) utilizaram pedômetro em 13 vacas Wagyu não-lactantes e relataram que a atividade durante o estro diminuiu significativamente no verão (175 ± 10 , $P < 0,001$) comparada com o inverno (410 ± 30 , $P < 0,001$). As condições climáticas quentes são os principais fatores que deprimem a eficiência reprodutiva, devido à redução da duração e da intensidade do estro, contribuindo para baixas taxas de detecção e prenhez (Reith et al., 2017).

1.7.2 NUTRIÇÃO E ESTRO

O fraco desempenho reprodutivo de vacas leiteiras em lactação é um transtorno complexo no processo de adaptação metabólica pós-parto que regula a retomada da atividade ovariana (Berry et al., 2014). O fator mais importante para explicar o menor desempenho reprodutivo no pós-parto é o balanço energético negativo da vaca (Reith et al., 2017) nesse período. Influências nutricionais durante o período de transição (± 4 semanas do parto) podem ser de particular importância (Overton e Waldron, 2004), mas o efeito da dieta sobre a fertilidade durante este período é complexo e multifatorial. Nutrientes podem interagir para alterar a disponibilidade, absorção ou produção de outros nutrientes e influenciar a partição de energia e produção futura de leite (Degaris et al., 2008; Berry et al., 2014). O estro é afetado negativamente por alterações nos metabólitos sanguíneos e perfis hormonais, afetando as concentrações plasmáticas de glicose, insulina, IGF-I, ácidos graxos não esterificados e β -hidroxibutirato (Wathes et al., 2007). O balanço energético negativo diminui a produção hipotalâmica de GnRH e, por sua vez, suprime a secreção pulsátil de LH e as concentrações circulantes de estrogênio e progesterona (Wiltbank et al., 2006; Wathes et al., 2007), explicando a diminuição na duração e intensidade do estro (Lopez et al., 2004). Quando as reservas corporais são mobilizadas para compensar o balanço energético negativo, as funções reprodutivas dos animais também são afetadas (Liefers et al., 2003).

1.7.3 PROTOCOLOS HORMONAIIS E ESTRO

A inseminação artificial (IA) é uma técnica, que permite melhorar rapidamente a genética do rebanho, porém, na maioria das vezes, o produtor relata dificuldade na aplicação da técnica, principalmente quanto há necessidade de detecção visual do estro (Bilego, 2009). A sincronização do estro com hormônios reprodutivos tem sido estratégica para eliminar a necessidade de detecção de estro (Dolecheck et al., 2016). O objetivo é inseminar simultaneamente todas as vacas submetidas ao protocolo hormonal. A administração de GnRH resulta na ovulação e formação de um corpo lúteo novo ou acessório e coincide com o início de uma nova onda folicular. O corpo lúteo regride após a injeção de PGF2 α que normalmente é administrada 7 dias depois. As vacas recebem uma segunda injeção de GnRH 48 horas após o tratamento luteolítico para induzir ovulação fértil seguida pela inseminação 24 horas depois usando dispositivo intravaginal liberador de progesterona para sincronização de cio (Reith et al., 2017). López-Gatius et al. (2005) compararam o comportamento da atividade do estro natural e induzido e encontraram padrões de atividade semelhantes para os dois sistemas. Dessa forma, a associação de protocolos hormonais com o controle de atividade dos animais em estro pode aumentar as taxas de prenhez do rebanho. Dolecheck et al. (2016) não encontraram diferença na probabilidade de prenhez ou perda de gestação entre vacas com estro detectadas pelo aumento da atividade de caminhada, e vacas que foram submetidas a programa de sincronização da ovulação. Fricke et al. (2014) também compararam a eficácia da IATF com ou sem detecção de estro, comprovando, que o uso de dispositivos automáticos de detecção de estro em programas de IATF resultou em redução do tempo de serviço de 7,5 a 12,4 dias.

1.8 MODELOS PARA TOMADA DE DECISÃO COM BASE EM *MACHINE LEARNING*

As incertezas do futuro dificultam as decisões nos processos de escolha. No entanto, estas decisões são tomadas com as informações disponíveis (ainda que incompletas). Quando uma ação deve ser executada em ambientes ainda desconhecidos e com variabilidade temporal, é importante implementar alternativas que possam prover maior conjunto de informações e minimizar riscos. Métodos de *Machine Learning* são

úteis para facilitar os processos de decisão, podendo complementar as informações existentes.

A habilidade de prever adequadamente e entender as relações dinâmicas entre variáveis são de grande importância. Grande parte desta metodologia estatística é aplicada em modelos nos quais se assume que as observações variam no tempo. A adoção de *Machine Learning* permite criar automaticamente modelos estatísticos que possam gerar previsões com base no que aprenderam. Os algoritmos são fornecidos com registros de dados contendo conjunto de variáveis e usam essas informações para aprender padrão que descreve a variável resposta. Esse processo de aprendizado é conhecido como “treinamento” (Hempstalk et al., 2015).

O uso de técnicas de *Machine Learning* pode melhorar a qualidade das previsões devido à sua capacidade de modelar relações complexas entre variáveis, tais como, não-linearidade e interações (Gianola et al., 2011). Esses algoritmos estão disponíveis em softwares comerciais e de domínio público. No entanto, o usuário deve entender conceitos básicos, como construir conjuntos de treinamento e testes que sejam independentes e apropriados para o uso pretendido, como ajustar os parâmetros do modelo ou algoritmo e como evitar o ajuste excessivo dos dados de treinamento e conclusões irreais sobre a capacidade preditiva do modelo em aplicações futuras (Weigel et al., 2017). A flexibilidade dos algoritmos de aprendizado de máquina pode ser valiosa ao incorporar o conhecimento biológico obtido a partir de experimentos planejados, juntamente com quantidades massivas de dados gerados pelos sistemas automáticos das fazendas leiteiras.

A maioria do desenvolvimento e uso de algoritmos implementa elementos de controle estatístico de processo (MacGregor e Kourti, 1995), exigindo o uso de tentativa e erro e o desenvolvimento de desvios dos valores de referência. O *Machine Learning* surge como nova abordagem na previsão de eventos. Na Ciência Animal, os primeiros estudos com *Machine Learning* foram desenvolvidos na área da genética (Gianola et al., 2011) e atualmente têm aplicação para detecção do momento do parto (Borchers et al., 2017), cetose subclínica (Ehret et al., 2015), estro (Dolecheck et al., 2015; Higaki et al., 2018) e consumo de matéria seca (Dorea et al., 2018). No entanto, a maioria das tecnologias de detecção antecipada disponíveis comercialmente não utiliza *Machine Learning* para o desenvolvimento de alertas de tomada de decisão.

Dolecheck et al. (2015) comprovaram o potencial de detectar estro utilizando *Machine Learning* (*Artificial Neural Network* e *Randon Forest*) com base nas variáveis:

escore de atividade, movimentação auricular, movimentação das pernas, número de passos, tempo de espera, ruminação, tempo de alimentação e temperatura do retículo rúmen. Já Higaki et al. (2018) conseguiram previsões acuradas e precisas de estro com base em medições contínuas de temperatura vaginal e condutividade por modelos de ANN.

Entre as opções de processos que envolvem *Machine Learning*, a adoção de *Artificial Neural Network (ANN)* e *Randon Forest (RF)* geram modelos classificadores, que aprendem um padrão para o status de estro da variável de classe binária com base nos exemplos fornecidos durante a fase de treinamento. Esses modelos são comumente usados em tarefas de classificação e representam diferentes abordagens de *Machine Learning*.

1.8.1 ARTIFICIAL NEURAL NETWORK

Métodos de ANN são abordagens de propósito geral para aprender relações funcionais à partir de dados sem a necessidade de defini-las a priori (Murphy, 2012; Michalski et al, 2013). O potencial da aprendizagem profunda (*deep learning* ou *deep neural network*) permite explorar melhor a disponibilidade de conjuntos de dados cada vez maiores e de maior dimensão por meio do treinamento de redes complexas com múltiplas camadas que capturam sua estrutura interna (Angermueller et al., 2016).

A estrutura de funcionamento da ANN está representada na Figura 1. A ANN recebe dados em uma camada de entrada (*input*), que são transformados de maneira não linear através de múltiplas camadas ocultas, antes que as saídas finais sejam computadas na cama de saída (Painel A). Neurônios (ou unidade) em uma camada oculta ou de saída estão conectados a todos os neurônios da camada anterior através de pesos (w_1), representados na Figura 1 pelas setas. Para cada neurônio, os valores atribuídos aos pesos (w_1) são multiplicados pelo valor de cada input (quase sempre entre 0 e 1). O resultado da soma da multiplicação de todos os pesos e *inputs* (peso x *input*) é utilizado em uma função de ativação, na Figura 1 representado pela função ReLu (*Rectifier Linear Unit*). O resultado após a transformação pela função de ativação é então utilizado como valor do neurônio (0,3; 0,8; 0; 0,1, Figura 1).

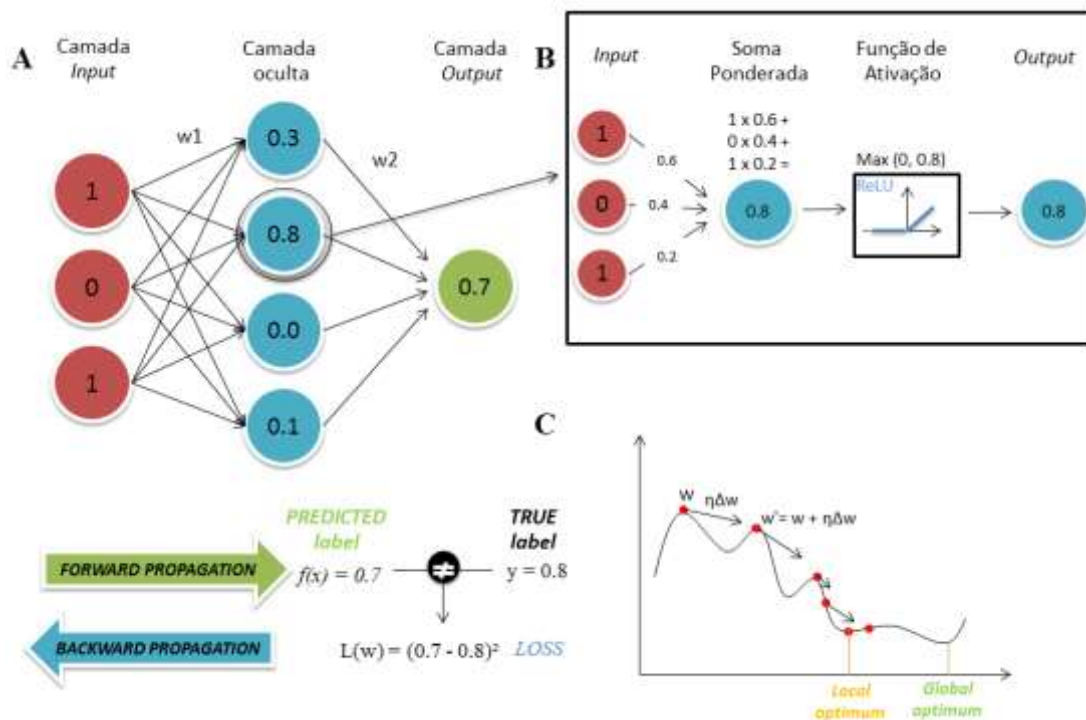


Figura 1. Exemplo de funcionamento de um tipo de Rede Neural Artificial. Adaptado de Angermueller et al. (2016)

Os pesos w (i) entre os neurônios são parâmetros livres que capturam a representação do modelo dos dados e são aprendidos com amostras de *input / output*. O aprendizado minimiza uma função de perda (*Loss function*) $L(w)$ que mede o ajuste da saída do modelo ao valor observado de uma amostra (painel A, inferior). Esta minimização é um desafio, já que a função de perda é de alta dimensão e não convexa, semelhante a uma paisagem com muitas colinas e vales (painel C). Em outras palavras, na busca pela otimização dos valores de peso que minimizam o erro, o algoritmo pode ficar preso em determinada região e dessa forma não encontrar o valor do peso que mais minimiza o erro. Este fato é denominado *local minima*. Demorou várias décadas antes que o algoritmo de *backward propagation* fosse aplicado pela primeira vez para calcular um gradiente de função de perda (*Loss*) via derivadas parciais (Rumelhart et al, 1988), possibilitando treinamento eficiente de redes neurais usando gradiente estocástico (*stochastic gradient descent*). Durante a aprendizagem, o *predicted label* é comparado com o *true label* para calcular uma *loss* para o conjunto atual de pesos do modelo. A perda é então *backward propagated* através da rede para calcular os gradientes da função de perda e atualização (painel A). A função de perda $L(w)$ é tipicamente otimizada usando descida baseada em gradiente. Em cada etapa, o vetor de peso atual

(ponto vermelho) é movido ao longo da direção da descida mais íngreme dw (seta de direção) pela taxa de aprendizado g (comprimento do vetor). A deterioração da taxa de aprendizado ao longo do tempo permite explorar diferentes domínios da função de perda saltando sobre vales no início do treinamento (lado esquerdo) e ajustando parâmetros com menores taxas de aprendizado nos estágios posteriores do treinamento do modelo. Embora o aprendizado em redes neurais profundas continue sendo uma área ativa de pesquisa, os pacotes de software existentes já podem ser aplicados sem o conhecimento dos detalhes matemáticos envolvidos.

A rede neural é treinada para todos os hiperparâmetros citados acima (número de neurônios, número de camadas intermediárias (*hidden layers*), taxa de aprendizado, otimizador (Stochastic Gradient Descent, função de ativação) precisam ser buscados e otimizados pelo usuário, para que a arquitetura da rede neural seja definida.

1.8.2 *RANDOM FOREST*

RF é um aprendiz conjunto que cria uma “floresta” de árvores de decisão e prediz a classe mais popular estimada pelo conjunto de árvores (Breiman, 2001). Cada árvore é fornecida com conjunto aleatório de instâncias de treinamento amostradas com substituição de todo o conjunto de treinamento. A intenção deste passo é criar um conjunto diversificado de árvores. O algoritmo difere das árvores de decisão ensacadas (que também fornecem subconjuntos selecionados aleatoriamente para cada árvore) porque durante o treinamento o algoritmo seleciona aleatoriamente um subconjunto de recursos disponíveis para seleção em cada divisão na árvore (Hempstalk et al., 2015).

O método de *RF* é baseado na classificação da árvore de decisão e desenvolve um grupo de modelos de classificação estruturados em árvore (Figura 2). Cada árvore contribui com uma opinião de como os dados devem ser classificados (Breiman, 2001; Bishop, 2006; Shahinfar et al., 2014). Em seguida, um grande número de árvores é gerado, e a classe que mais se repete é usada como modelo final.

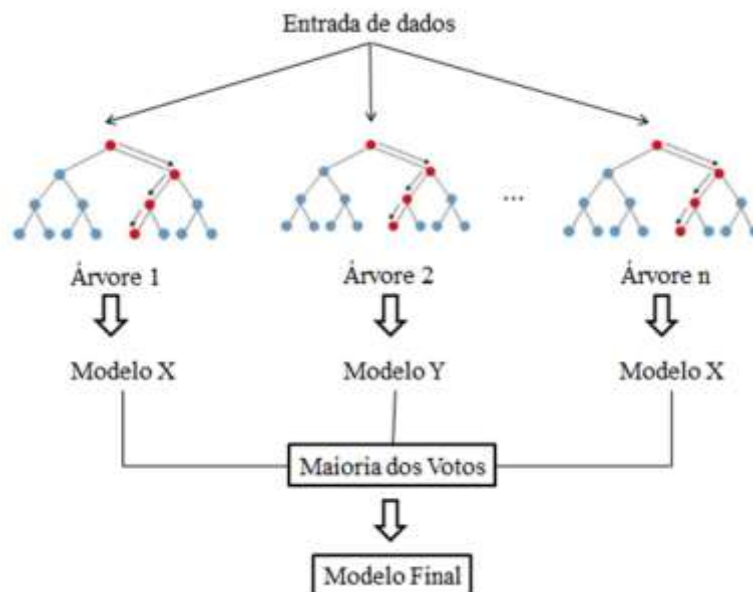


Figura 2. Processo de classificação baseado em Random Forest. Um redesenho da figura inspirada original obtida no seguinte website: <https://www.linkedin.com/pulse/random-forest-algorithm-in-teractive-discussion-niraj-kumar>

1.8.3 REGRESSÃO LOGÍSTICA

A regressão linear é utilizada para expressar uma variável de classe em combinação linear com outra variável. No entanto, ela é projetada para prever um valor numérico real e não pode manipular uma classe categórica ou binária (ou seja, concebida ou não). Para superar isso, um modelo pode ser construído para cada valor de classe que, idealmente, prevê 1 para esse valor de classe e 0, caso contrário, e no tempo de previsão atribui o valor de classe cujo modelo prevê a maior probabilidade. Infelizmente, não é garantido que as funções de regressão produzam uma probabilidade entre 0 e 1 e, portanto, a classe de destino deve primeiro ser transformada em um novo espaço antes de ser aprendida. Isto é conseguido usando uma transformação de log, e este método de regressão é conhecido como regressão logística (Witten et al., 2011). Os coeficientes da regressão são estimados a partir do conjunto dados, pelo método da máxima verossimilhança, em que encontra uma combinação de coeficientes que maximiza a probabilidade da amostra ter sido observada.

1.9 REFERÊNCIAS

ALAWNEH, J.I.; WILLIAMSON, N.B.; BAILEY, D. Comparison of a camera-software system and typical farm management for detecting oestrus in dairy cattle at pasture. **New Zealand Veterinary Journal**, v.54, n.2, p.73-77, 2006

ANGERMUELLER, C., PÄRNAMAA, T., PARTS, L., & STEGLE, O. Deep learning for computational biology. **New Zealand Veterinary Journal**, p1–16, 2016.

AT-TARAS, E.E.; SPAHR, S.L. Detection and characterization of estrus in dairy cattle with an electronic heatmount detector and an electronic activity tag. **Journal Dairy Science**, v.84, n.4, p.792–798, 2001.

AUNGIER, S. P. M., J. F. ROCHE, P. DUFFY, S. SCULLY, AND M. A. CROWE. The relationship between activity clusters detected by an automatic activity monitor and endocrine changes during the periestrus period in lactating dairy cows. **Journal Dairy Science**. 98:1666–1684, 2015.

BEER, G., M. ALSAOD, A. STARKE, G. SCHUEPBACH-REGULA, H. MÜLLER, P. KOHLER, AND A. STEINER. Use of extended characteristics of locomotion and feeding behavior for automated identification of lame dairy cows. **PLOS One** 11:0155796, 2016.

BERRY, D. P., E. WALL, AND J. PRYCE. Genetics and genomics of reproductive performance in dairy and beef cattle. **Animal** 8:105– 121, 2014.

BEWLEY, J. Opportunities for monitoring and improving animal welfare using precision dairy monitoring technologies. **Journal Animal Science**. 94(Supplement2):11, 2016.

BISHOP, C. M. Pattern Recognition and Machine Learning. **Springer, New York, NY**, 2006.

BILEGO, U. O. Avaliação ovariana de novilhas F1 HG submetidas ao protocolo ovsynch em duas estações do ano. 51f. **Dissertação (Mestrado em ciência animal)** - Universidade Federal de Goia, 2009.

BREHME, U.; BREHME, A. U.; STOLLBERGA, U.; HOLZB, R.; SCHLEUSENER, T. Alt pedometer—new sensor-aided measurement system for improvement in oestrus detection. **Computers and electronics in agriculture**, v.62, n.1, p.73–80, 2008.

BREIMAN, L. Random forests. **Mach. Learn.** 45:5–32, 2001.

BRITT J.H., SCOTT R.G., ARMSTRONG J.D. AND WIITACRE M.D. Determinants of estrous behavior in lactating Holstein cows. **Journal of Dairy Science** 69, 2195–2202. 1986.

BRUYÈRE, P.; HÉTREAU, T.; PONSART, C.; GATIEN, J.; BUFF, S.; DISENHAUS, C. Can vídeo cameras replace visual estrus detection in dairy cows? **Theriogenology**, v.77, n.3, p.525- 530, 2012.

BURNETT, T. A., A. M. L. MADUREIRA, B. F. SILPER, A. C. C. FERNANDES, AND R. L. A. CERRI. Integrating an automated activity monitor into an artificial insemination program and the associated risk factors affecting reproductive performance of dairy cows. **Journal of Dairy Science**. 100:5005–5018, 2017.

CARVALHO, P. D., A. H. SOUZA, M. C. AMUNDSON, K. S. HACKBART, M. J. FUENZALIDA, M. M. HERLIHY, H. AYRES, A. R. DRESCH, L. M. VIEIRA, J. N. GUENTHER, R. R. GRUMMER, P. M. FRICKE, R. D. SHAVER, AND M. C. WILTBANK. Relationships between fertility and postpartum changes in body condition and body weight in lactating dairy cows. **Journal of Dairy Science**. 97:3666–3683. <https://doi.org/10.3168/jds.2013-7809>, 2014.

CAVALIERI, J.; EAGLES, V.; RYAN, M.; MACMILLAN, K.L. Comparison of four methods for detection of oestrus in dairy cows with resynchronised oestrous cycles. **Australian Veterinary Journal**, v.81, n. 7, p.422-425, 2003. <https://doi.org/10.1111/j.1751-0813.2003.tb11553.x>

DE RENSIS, F., AND R. J. SCARAMUZZI. Heat stress and seasonal effects on reproduction in the dairy cow—A review. **Theriogenology** 60:1139–1151. [https:// doi .org/ 10 .1016/ s0093 -691x\(03\)00126 -2](https://doi.org/10.1016/s0093-691x(03)00126-2), 2003.

DE SILVA, A. W. M. V., G. W. ANDERSON, F. C. GWAZDAUSKAS, M. L. MCGILLIARD, AND J. A. LINEWEAVER. Interrelationships with estrous behavior and conception in dairy cattle. **Journal of Dairy Science**. 64:2409–2418, 1981.

DEGARIS, P. J., I. LEAN, A. RABIEE, AND C. HEUER. Effects of increasing days of exposure to prepartum transition diets on milk production and milk composition in dairy cows. **Aust. Vet. J.** 86:341–351, 2008.

DISKIN, M. G.; SREENAN, J. M. Expression and detection of oestrus in cattle. **Reproduction Nutrition Development**, v.40, n. 5, p.481–491, 2000.

DOLECHECK K.A., SILVIA W.J., HEERSCHKE G., WOOD C.L., MCQUERRY K.J. AND BEWLEY J.M. A comparison of timed artificial insemination and automated activity monitoring with hormone intervention in 3 commercial dairy herds. **Journal of Dairy Science** 99, 1506–1514, 2016.

DRESCHEL S. Untersuchungen zur zyklusabhängigen Vokalisation und Charakterisierung von Verhaltensparametern im periöstrischen Zeitraum von Jungrindern. **Doctoral thesis**, University of Rostock, Germany, 2014.

EASTWOOD, C., D. CHAPMAN, AND M. PAINE. Networks of practice for co-construction of agricultural decision support systems: Case studies of precision dairy farms in Australia. **Agric. Syst.** 108:10–18, 2012.

EASTWOOD, C., L. KLERKX, AND R. NETTLE. Dynamics and distribution of public and private research and extension roles for technological innovation and diffusion: Case studies of the implementation and adaptation of precision farming technologies. **J. Rural Stud.** 49:1–12, 2017.

EDWARDS, J. P., B. T. DELA RUE, AND J. G. JAGO. Evaluating rates of technology adoption and milking practices on New Zealand dairy farms. **Anim. Prod. Sci.** 55:702, 2015. <https://doi.org/10.1071/an14065>

FIRK, R.; STAMER, E.; JUNGE, W.; KRIETER, J. Automation of oestrus detection in dairy cows: a review. **Livestock Production Science**, v.75, n.3 , p.219–232, 2002.

FRICKE P.M, VALENZA A, GIORDANO J.O, AMUNDSON M.C AND LOPES G J.R. Reproductive performance of lactating dairy cows managed for first service using timed artificial insemination with or without detection of estrus using an accelerometer system. **Journal of Dairy Science** 97, 2014.

FRIGGENS, N.C.; BJERRING, M.; RIDDER, C.; HØJSGAARD, S.; LARSEN, T. Improved detection of reproductive status in dairy cows using milk progesterone measurements. **Reproduction in Domestic Animals**, v.43, n. Supplement s2, p.113–121, 2008.

FONSECA, A. P. Puberdade e características da dinamica follicular de novilhas F1 holandês x gir com fenótipos divergentes para consumo alimentar residual. **Escola de Veterinária UFMG**, p. 60, 2017.

GAILLARD C, BARBU M, SØRENSEN T, SEHESTED J, CALLESEN H AND VESTERGAARD M. Milk yield and estrous behavior during eight consecutive estruses in Holstein cows fed standardized or high energy diets and grouped according to live weight changes in early lactation. **Journal of Dairy Science** 99, 3134–3143, 2016.

GIANOLA, D., H. OKUT, K. A. WEIGEL, AND G. J. M. ROSA. Predict- ing complex quantitative traits with Bayesian neural networks: A case study with Jersey cows and wheat. **BMC Genet.** 12:87–99, 2011. <https://doi.org/10.1186/1471-2156-12-87>.

GLOROT X, BORDES A, BENGIO Y. Deep sparse rectifier neural networks. In International Conference on Artificial Intelligence and Statistics, pp 315 – 323. **JMLR Conference Proceedings**, 2011.

HEMPSTALK, K., MCPARLAND, S., & BERRY, D. P. Machine learning algorithms for the prediction of conception success to a given insemination in lactating dairy cow. **Journal of Dairy Science**, 98(8), 5262–5273, 2015. <https://doi.org/10.3168/jds.2014-8984>

HIGAKI, S., MIURA, R., SUDA, T., ANDERSSON, L. M., OKADA, H., ZHANG, Y. YOSHIOKA, K. Estrous detection by continuous measurements of vaginal temperature and conductivity with supervised machine learning in cattle. **Theriogenology**. 2018. <https://doi.org/10.1016/j.theriogenology.2018.09.038>

HOSMER, D. W., S. LEMESHOW, AND R. X. STURDIVANT. Applied Logistic Regression. **Wiley, Hoboken**, NJ. 2013.

HOLMAN A, THOMPSON J, ROUTLY JE, CAMERON J, JONES DN, GROVE-WHITE D, SMITH RF AND DOBSON H. Comparison of oestrus detection methods in dairy cattle. **The Veterinary Record** 169, 47, 2011.

HURNICK JF, KING GJ AND ROBERTSON HA 1975. Estrous and related behavior in IPCC (Intergovernmental Panel on Climate Change). **Summary for policy makers**. Page 23. Cambridge Press, Cambridge, UK, 2007.

JAGO, J., C. EASTWOOD, K. KERRISK, AND I. YULE. Precision dairy farming in Australasia: Adoption, risks and opportunities. **Anim. Prod. Sci.** 53:907–916, 2013. <https://doi.org/10.1071/an12330>.

JONSSON, R., M. BLANKE, N. K. POULSEN, F. CAPONETTI, AND S. HOJSGAARD. Oestrus detection in dairy cows from activity and lying data using on-line individual models. **Comput. Electron. Agric.** 76:6–15, 2011.

KADZERE, C. T., M. R. MURPHY, N. SILANIKOVE, AND E. MALTZ. Heat stress in lactating dairy cows: a review. **Livest. Prod. Sci.** 77:59–91, 2002. [https://doi.org/10.1016/s0301-6226\(01\)00330-x](https://doi.org/10.1016/s0301-6226(01)00330-x).

KERBRAT S AND DISENHAUS C. A proposition for an updated behavioural characterization of the oestrus period in dairy cows. **Applied Animal Behaviour Science** 87, 223–238. 2004.

KRIETER, J., E. STAMER, AND W. JUNGE. Control charts and neural networks for oestrus detection in dairy cows. Pages 133–136 in Proc. **GIL Jahrestagung, Potsdam, Germany**. Gesellschaft für In-formatik in der Land- Forst- und Ernährungswirtschaft e.V., Göt-tingen, Germany, 2006.

LEDGERWOOD, D. N., C. WINCKLER, AND C. B. TUCKER. Evaluation of data loggers, sampling intervals, and editing techniques for measuring the lying behavior of dairy cattle. **Journal of Dairy Science**. 93:5129–5139, 2010.

LIEFERS SC, VEERKAMP RF, TE PAS MFW, DELAVAUD C, CHILLIARD Y AND VAN DER LENDE T. Leptin concentrations in relation to energy balance, milk yield, intake, live weight, and estrus in dairy cows. **Journal of Dairy Science** 86, 799–807, 2003.

LÓPEZ H, SATTER LD AND WILTBANK MC 2004. Relationship between level of milk López-Gatius F, López-Béjar M, Fenech M and Hunter RHF. Ovulation failure and double ovulation in dairy cattle: risk factors and effects. **Theriogenology** 63, 1298–1307, 2005.

LÓPEZ-GATIUS, F., M. LÓPEZ-BÉJAR, M. FENECH, AND R. H. F. HUNTER. Ovulation failure and double ovulation in dairy cattle: Risk factors and effects. **Theriogenology**63:1298/1307,2005.<http://dx.doi.org/10.1016/j.theriogenology.2004.06.010>.

LUKAS, J. M., J. K. RENEAU, AND J. G. LINN. Water intake and dry matter intake changes as a feeding management tool and indicator of health and estrus status in dairy cows. **Journal of Dairy Science**. 91:3385–3394, 2008.

MACGREGOR, J. F., AND T. KOURTI. Statistical process control of multivariate processes. **Control Eng. Pract.** 3:403–414, 1995.

MADUREIRA, A. M. L., B. F. SILPER, L. B. POLSKY, T. A. BURNETTE, E. L. DRAGO FILHO, S. SORIANO, A. F. SICA, J. L. M. VASCONCELOS, AND R. L. A. CERRI. Effects of expression of estrus measured by activity monitors on ovarian dynamics and conception risk in Holstein cows. **Journal of Dairy Science**. 98(Suppl. 2):874, 2015.

MICHALSKI R.S., CARBONELL J.G., MITCHELL T.M. Machine learning: an artificial intelligence approach. Berlin Heidelberg: **Springer Science & Business Media**, 2013.

MURPHY KP Machine learning: a probabilistic perspective. **Cambridge: MIT Press**, 2012.

MURPHY, C., R. NETTLE, AND M. PAINE. The evolving extension environment: Implications for dairy scientists. **Anim. Prod. Sci.** 53:917–923, 2013.

NIELSEN, P. P. Automatic registration of grazing behaviour in dairy cows using 3D activity loggers. **Appl. Anim. Behav. Sci.** 148:179–184, 2013.

OVERTON, T., AND M. WALDRON. Nutritional management of transition dairy cows: strategies to optimize metabolic health. **J. Dairy Sci.** 87:E105–E119, 2004.

PALMER, M.A.; OLMOS, G.; BOYLE, L.A.; MEE, J.F. Estrus detection and estrus characteristics in housed and pastured Holstein–Friesian cows. **Theriogenology**, v.74, n.2, p.255–264, 2010.

PERALTA, O. A., R. E. PEARSON, AND R. L. NEBEL. Comparison of three estrus detection systems during summer in a large commercial dairy herd. **Anim. Reprod. Sci.** 87:59–72, 2005. <https://doi.org/10.1016/j.anireprosci.2004.10.003>.

PEREIRA, M. H., M. C. WILTBANK, L. F. BARBOSA, W. M. COSTA, M. A. CARVALHO, AND J. L. VASCONCELOS. Effect of adding a gonadotropin-releasing-hormone treatment at the beginning and a second prostaglandin F2 α treatment at the end of an estradiol-based protocol for timed artificial insemination in lactating

dairy cows during cool or hot seasons of the year. **Journal of Dairy Science**. 98:947–959, 2015.

PORTO-FILHO, R.M.; BARUSELLI, P.S.; MADUREIRA, E.H. Uso da radiotelemetria para detecção do estro em fêmeas búfalas: luteólise durante duas fases do ciclo estral, ultra-sonografia da ovulação e perfis hormonais. **Boletim de Medicina Veterinária**, v. 1, n.1, p.13-32, 2005.

REITH S, PRIES M, VERHÜLSDONK C, BRANDT H AND HOY S 2014. Influence of estrus on dry matter intake, water intake and BW of dairy cows. *Animal* 8, 748–753. Saint-Dizier M and Chastant-Maillard S. Towards an automated detection of oestrus in dairy cattle. **Reproduction in Domestic Animals** 47, 1056–1061, 2012.

REITH, S., & HOY, S. Review : Behavioral signs of estrus and the potential of fully automated systems for detection of estrus in dairy cattle, **Anim. Prod. Sci.** 1–10, 2017. <https://doi.org/10.1017/S1751731117001975>

RODRIGUES, J. P. P.; PEREIRA, L. G. R.; NETO, H. C. D.; LOMBARDI, M. C.; LAGE, C. F. A.; COELHO, S. G.; SACRAMENTO, J. P.; MACHADO, F. S.; TOMICH, T. R.; MAURÍCIO, R. M.; CAMPOS, M. M. Technical note: Evaluation of an automatic system for monitoring rumination time in weaning calves. **Livestock Science**, p. 1-8, 2018.

ROELOFS, J.; LÓPEZ-GATIUS, F.; HUNTER, R. H. F.; et al., When is a cow in estrus? Clinical and practical aspects. **Theriogenology**, v. 74, n. 3, p. 327-344, 2010.

RÖTTGEN, V., BECKER, F., TUCHSCHERER, A., WRENZYCKI, C., DÜPJAN, S., SCHÖN, P. C., & PUPPE, B. Vocalization as an indicator of estrus climax in Holstein heifers during natural estrus and superovulation. **Journal of Dairy Science**, (1), 2383–2394, 2018. <https://doi.org/10.3168/jds.2017-13412>

RUMELHART D.E., HINTON G.E., WILLIAMS R.J. Learning representations by back-propagating errors. **Cogn Model** 5: 1m 1998.

RUTTEN, C. J., W. STEENEVELD, C. INCH AISRI, AND H. HOGEVEEN. An ex ante analysis on the use of activity meters for automated estrus detection: To invest or not to invest? **Journal of Dairy Science**. 97:6869–6887, 2014.

SAINT-DIZIER, M., CHASTANT-MAILLARD, S., Towards an automated detection of oestrus in dairy cattle. **Reproduction in Domestic Animals** 47, 1056–1061, 2012.

SAKATANI, M., A. Z. BALBOULA, K. YAMANAKA, AND M. TAKAHASHI. Effect of summer heat environment on body temperature, estrous cycles and blood antioxidant levels in Japanese Black cow. **Journal of Dairy Science**. 83:394–402, 2012. <https://doi.org/10.1111/j.1740-0929.2011.00967.x>.

SAUMANDE, J. Electronic detection of oestrus in postpartum dairy cows: Efficiency and accuracy of the DEC (R) (showheat) system. **Livest. Prod. Sci.** 77:265–271, 2002.

SCHIRMANN, K., N. CHAPINAL, D. M. WEARY, W. HEUWIESER, AND M. A. G. VON KEYSERLINGK. Rumination and its relationship to feeding and lying behavior in Holstein dairy cows. **Journal of Dairy Science**. 95:3212–3217, 2012.

SCHÖN PC, HÄMEL K, PUPPE B, TUCHSCHERER A, KANITZ W AND MANTEUFFEL G. Altered vocalization in rate during the estrous cycle in dairy cattle. **Journal of Dairy Science** 90, 202–206, 2007.

SCHUTZ, K. E., N. R. COX, AND L. R. MATTHEWS. How important is shade to dairy cattle? Choice between shade or lying following different levels of lying deprivation. **Appl. Anim. Behav. Sci.** 114:307–318, 2008. <https://doi.org/10.1016/j.applanim.2008.04.001>.

SENGER P.L. The estrus detection problem: new concepts, technologies, and possibilities. **Journal of Dairy Science** 77, 2745–2753, 1994.

SHAHINFAR, S., D. PAGE, J. GUENTHER, V. CABRERA, P. FRICKE, AND K. A. WEIGEL. Prediction of insemination outcomes in Holstein dairy cattle using alternative machine learning algorithms. **Journal of Dairy Science**. 97:731–742, 2014.

SILPER, B. F., I. ROBLES, A. M. L. MADUREIRA, T. A. BURNETT, M. M. REIS, A. M. DE PASSILLE, J. RUSHEN, AND R. L. A. CERRI. Automated and visual measurements of estrous behavior and their sources of variation in Holstein heifers I: Walking activity and behavior frequency. **Theriogenology** 84:312–320, 2015.

STEVENSON, J. S., S. L. HILL, R. L. NEBEL, AND J. M. DEJARNETTE. Ovulation timing and conception risk after automated activity monitoring in lactating dairy cows. **Journal of Dairy Science**. 97:4296–4308, 2014. [https:// doi .org/ 10 .3168/ jds .2013 - 7873](https://doi.org/10.3168/jds.2013-7873).

TEDESCHI, L. O. Assessment of the adequacy of mathematical models. **Agric. Syst.** 89:225–247, 2004. [https:// doi .org/ 10 .1016/ j .agsy .2005 .11 .004](https://doi.org/10.1016/j.agsy.2005.11.004).

THATCHER, W. W., AND R. J. COLLIER. Effects of climate on bovine reproduction. **Curr. Ther. Theriogenol.** 2:301–309, 1986.

VALENZA, A.; GIORDANO, J.O.; LOPES, G. JR.; VINCENTI, L.; AMUNDSON, M.C.; FRICKE, P.M. Assessment of an accelerometer system for detection of estrus and treatment with gonadotropin-releasing hormone at the time of insemination in lactating dairy cows. **Journal of Dairy Science**, v.95, n.12, p.7115-27, 2012.

VAN VLIET, J. H.; VAN EERDENBURG, F. J. C. M. Sexual activities and oestrus detection in lactating Holstein cows. **Appl. Anim. Behav. Sci.**, v. 50 n. 1, p. 57-69, 1996.

WATHES DC, FENWICK M, CHENG Z, BOURNE N, LLEWELLYN S, MORRIS DG, KENNY D, MURPHY J AND FITZPATRICK R. Influence of negative energy balance on cyclicity and fertility in the high producing dairy cow. **Theriogenology** 68S, S232–S241, 2007.

WEIGEL, K. A., VANRADEN, P. M., NORMAN, H. D., & GROSU, H. A 100-Year Review : Methods and impact of genetic selection in dairy cattle — From daughter –

dam comparisons to deep learning algorithms. **Journal of Dairy Science** 1, 10234–10250, 2017. <https://doi.org/10.3168/jds.2017-12954>

WEST, J. W. Effects of heat-stress on production in dairy cattle. **Journal of Dairy Science**. 86:2131–2144, 2003. [https://doi.org/10.3168/jds.S0022-0302\(03\)73803-x](https://doi.org/10.3168/jds.S0022-0302(03)73803-x).

WILTBANK M, LOPEZ H, SARTORI R, SANGSRITAVONG S AND GÜMEN A. Changes in reproductive physiology of lactating dairy cows due to elevated steroid metabolism. **Theriogenology** 65, 17–29, 2006.

WILTBANK MC, GÜMEN A AND SARTORI R. Physiological classification of anovulatory conditions in cattle. **Theriogenology** 57, 21–52, 2002.

WITTEN, I. H., E. FRANK, AND M. A. HALL. Data Mining: Practical Machine Learning Tools and Techniques. **Morgan Kaufmann**, USA, 2011.

WOLFGER, B., B. W. JONES, K. ORSEL, AND J. M. BEWLEY. Technical note: Evaluation of an ear-attached real-time location monitoring system. **Journal of Dairy Science**. 100:2219–2224, 2017.

YÁNI, J. L.; SANTOLARIA, P.; GIRIBET, A.; LÓPEZ-GATIUS, F. Factors affecting walking activity at estrus during postpartum period and subsequent fertility in dairy cows. **Theriogenology**, v.66, n.8, p.1943–1950, 2006.

YÀNIZ JL, SANTOLARIA P, GIRIBET A AND LÓPEZ-GATIUS F. Factors affecting walking activity at estrus during postpartum period and subsequent fertility in dairy cows. **Theriogenology** 66, 1934–1950, 2006.

YOSHIOKA, H.; TANIMOTO, Y. Effectiveness of a Real-time Radiotelemetric Pedometer for estrus detection and Insemination in Japanese Black Cows. **Journal of Reproduction and Development**, v. 56, n.3, p. 351-355, 2010.

ZAHEDI, F. 1991. An introduction to neural networks and a comparison with artificial intelligence and expert systems. **Interfaces** 21:25–38, 1991.

II - OBJETIVOS

2.1 Objetivos Gerais

Os objetivos deste estudo foram: (i) avaliar a variação do consumo e comportamento alimentar de novilhas leiteiras causada pelo estro e (ii) determinar a eficiência de detecção e detecção antecipada (6 e 12 h de antecedência) do estro por modelos baseados em regressão logística ou envolvendo *Machine Learning* com base nos dados de comportamento e ingestão alimentar e/ou hídrica gerados por cochos e bebedouros eletrônicos.

2.2 Objetivos Específicos

(i) Avaliar a variação causada pelo estro de novilhas leiteiras no consumo e comportamento ingestivo de alimentos e água mensurados por cochos e bebedouros eletrônicos.

(ii) Identificar variáveis de consumo e comportamento alimentar obtidos em cochos e bebedouros eletrônicos que apresentam relação com a manifestação de estro por novilhas leiteiras.

(iii) Avaliar a sensibilidade, especificidade e acurácia na detecção e detecção antecipada (6 e 12 h de antecedência) de estro de modelos obtidos pelo método clássico de regressão logística e por algoritmos de *Machine Learning: Artificial Neural Network e Random Forest*.

(iv) Avaliar detecção antecipada do estro com seis e doze horas de antecedência da manifestação do estro em novilhas leiteiras com base em dados obtidos em cochos e bebedouros eletrônicos e modelos obtidos pelo método clássico de regressão logística e por algoritmos de *Machine Learning: Artificial Neural Network e Random Forest*.

(v) Avaliar séries temporais de 24 e 174 h para detecção e detecção antecipada de estro com seis e doze horas de antecedência da manifestação do estro por novilhas leiteiras com base em dados obtidos em cochos e bebedouros eletrônicos e modelos obtidos pelo método clássico de regressão logística e por algoritmos de *Machine Learning: Artificial Neural Network e Random Forest*.

(vi) Avaliar a possibilidade de excluir variáveis de consumo e utilizar modelos baseados somente com base em dados de comportamento alimentar para detecção e detecção antecipada (6 e 12 h de antecedência) do estro em novilhas leiteiras.

III - MATERIAL E MÉTODOS

O estudo foi realizado com base nos dados de dois ensaios experimentais aprovados pela Comissão de Ética no Uso de Animais (CEUA) da Embrapa Gado de Leite, sob protocolos número 21/2014 e 3403210316. Os dados do ensaio 1 foram obtidos entre dezembro de 2014 e julho de 2015 e do ensaio 2 entre maio de 2016 e agosto de 2016.

Animais, Instalações e Dieta

O estudo foi realizado no Campo Experimental José Henrique Bruschi da Embrapa Gado de Leite, em Coronel Pacheco, Minas Gerais, Brasil. Foram avaliados o consumo e o comportamento de ingestão de alimentos e de água, e da manifestação de estro em dois ensaios com novilhas mestiças Holandês x Gir (Hol/Gir). Apenas dados de novilhas que tiveram a observação visual do estro detectado por observador experiente ($n = 57$) foram incluídos na análise. O primeiro ensaio foi conduzido com 26 novilhas 5/8 Holandês/Gir, com $11,4 \pm 0,20$ meses e peso vivo (PV) de $328,81 \pm 25,08$ e o segundo ensaio com 31 novilhas F1 Holandês/Gir, com $17,69 \pm 0,93$ meses e PV de $415,69 \pm 34,84$ kg.

No primeiro ensaio, as novilhas foram alojadas em dois piquetes coletivos com seis cochos eletrônicos e um bebedouro eletrônico Intergado® (Cochos - AF 1000 JUNIOR/ Bebedouros - Modelo WD 1000; Intergado®; Betim, Minas Gerais, Brazil) por piquete, e no segundo ensaio, as novilhas foram mantidas em piquete com área total 0,2 ha com 12 cochos eletrônicos e 2 bebedouros eletrônicos (Intergado®). Em ambos os ensaios, as novilhas receberam dieta total (TMR) duas vezes ao dia (9h e 15h), composta por silagem de milho e concentrado (relações 70:30 no ensaio 1 e 75:25 no ensaio 2, tabela 2). Foram garantidas sobras de até 10% da quantidade fornecida para garantir o consumo *ad libitum*.

Tabela 2. Composição nutricional (base MS) da dieta total (TMR) oferecida para novilhas nos ensaios experimentais.

Item	Ensaio 1	Ensaio 2
Ingrediente (% da MS)		
Silagem de milho	70,0	75,0
Farelo de soja e Premix ¹	30,0	25,0
Composição % dos nutrientes (base na MS)		
MS*	48,2	43,8
PB	19,5	17,5
EE	2,8	2,4
FDN	40,6	42,2
FDA	21,5	23,7
Ca	0,6	0,6
P	0,4	0,4

* MS: matéria seca, PB: proteína bruta, EE: extrato etéreo, FDN: fibra em detergente neutro, FDA: fibra em detergente ácido, Ca: cálcio e P: fosforo. ¹Composição mineral e vitamínica: Cálcio (192 g / kg), Cobalto (90 mg / kg), Cobre (1500 mg / kg), Enxofre (25 g / kg), Flúor (897 mg / kg), Fósforo (80g / kg), Iodo (90 mg / kg), magnésio (20 g / kg), manganês (3000 mg / kg), selênio (25 mg / kg), sódio (103 g / kg), vitamina A (160.000 UI / kg) , Vitamina D3 (40.000 UI / kg), Vitamina E (1000 UI / kg) e Zinco (5000 mg / kg).

Todas as novilhas receberam brinco auricular com *transponder* eletrônico (TAG) (FDX - ISO 11784/11785; Allflex; Joinville, SC, Brasil), que permitiu o registro individual de consumo diário de TMR e de água pelo sistema eletrônico Intergado®. Os animais eram pesados diariamente em balança acoplada ao bebedouro, também de forma automatizada.

Comportamento Animal

O consumo e a dinâmica do comportamento alimentar/hídrico individual foram registrados diariamente durante todo o período experimental, de forma automatizada, utilizando sistema de monitoramento Intergado®, validado por Chizzotti et al. (2015).

Os cochos e bebedouros eram dotados de antena de identificação por radiofrequência e células de carga (capacidade de pesagem de 100 kg com ± 25 g de precisão) para pesagem de alimentos e água. Para cada visita ao cocho ou bebedouro, o sistema registrava o número do animal, o peso do conteúdo do cocho ou bebedouro e os tempos inicial e final de cada evento. Esses dados foram gravados continuamente em coletor de dados via cabo de rede e transferidos via pacotes de dados para software de gerenciamento Intergado®. As dimensões dos cochos e bebedouros eram de 0,80 m de largura, 0,80 m de comprimento e 0,40 m de profundidade.

Avaliação do estro

As novilhas foram avaliadas três vezes ao dia (7:00, 12:00 e 17:00 h) durante 30 minutos para monitoramento visual do comportamento do estro, em que o animal que aceitou monta foi considerado em estro (Roelofs et al., 2010). Foram observados 99 eventos de estro, sendo 32 observações no ensaio 1 e 67 no ensaio 2. As observações foram realizadas a 100 metros de distância do piquete onde estavam as novilhas, com o objetivo de não interferir no comportamento natural. Foram utilizados binóculos para facilitar a visualização das novilhas que foram identificadas por marcações únicas feitas na região da costela e na garupa por meio da descoloração dos pelos.

Conjunto de dados

Os dados de consumo e comportamento de ingestão de água e alimento foram coletados diretamente do software Intergado®. Duas séries temporais de 7 dias foram coletadas, sendo que uma das séries foi constituída por 7 dias consecutivos que antecedem o evento do estro (ESTRO), e a outra série temporal por 7 dias consecutivos após o dia do estro que resultaram em evento de não estro (ANESTRO). Todos os animais no conjunto de dados possuíram uma série temporal ESTRO e uma de ANESTRO. Com o intuito de desenvolver modelos capazes de detecção antecipada do ESTRO ou ANESTRO com horas de antecedência, as séries temporais foram fracionadas em intervalos de 6 horas. Para cada intervalo de 6 horas o total de consumo de alimento (CA, kg de Matéria Natural), número de visitas no cocho de alimento (VC), número de visitas no bebedouro (VA), tempo gasto consumindo alimento (TC) e tempo gasto bebendo água (TB) foram computados. Dessa maneira, as séries temporais ficaram com 28 observações (intervalos de 6 horas durante 7 dias), partindo do tempo $(t) = -174$ horas (horas antecedente ao estro) até a $t = 0$ (hora em que o estro foi detectado).

Análise dos dados

Primeiramente, um modelo misto foi utilizado para avaliar o efeito do estro no comportamento alimentar/hídrico e consumo. O modelo incluiu o efeito fixo de dias

(dias), e os efeitos aleatórios de experimento (exp) e animal aninhado a experimento (animal(exp)). Os dias foram considerados como medida repetida, e a estrutura de covariância escolhida foi a autoregressiva (AR1). As análises foram feitas utilizando o programa estatístico SAS (procedimento MIXED do SAS versão 9.3; SAS Institute, Inc., Cary, NC). As médias calculadas de cada variável resposta, para cada dia, foram comparadas utilizando teste de Tukey ($P < 0.05$).

Os modelos de detecção e detecção antecipada do estro foram estabelecidos utilizando três abordagens preditivas: Regressão Logística (RL); *Artificial Neural Network* (ANN); e *Random Forest* (RF). Para as abordagens preditivas, 12 conjuntos de covariáveis (Set) foram construídos para abordar os principais objetivos deste estudo. Conjuntos de covariáveis: *Set 1*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal a partir do tempo ($t = 0$ a -174 h; *Set 2*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal $t = -6$ a -174 h; *Set 3*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal $t = -12$ até -174 h; *Set 4*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal $t = 0$ a -174 h; *Set 5*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal $t = -6$ a -174 h; *Set 6*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal $t = -12$ a -174 h; *Set 7*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal $t = 0$ a -24 h; *Set 8*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal $t = -6$ a -24 h; *Set 9*) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal $t = -12$ a -24 h; *Set 10*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal $t = 0$ a -24); *Set 11*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal $t = -6$ a -24); *Set 12*) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal de $t = -12$ a -24 (Tabela 3). Todas as variáveis utilizadas neste estudo foram compiladas em intervalos de 6 horas.

A regressão logística foi realizada com as variáveis respostas binárias Estro (1) e Anestro (0), em que o estro foi considerado positivo para o teste. Modelos de RL Sets 1 a 6 não foram explorados, já que o número de variáveis excedia o de animais analisados. No entanto, foi utilizada a seleção de variáveis mais relevantes (variáveis que mais minimizaram erro quando foram contempladas nas redes ou árvores de

decisão), com base nos procedimentos de ANN e RF. Para comparar com a RL, as mesmas variáveis foram usadas para treinar a ANN e RF.

Tabela 3. Conjunto de covariáveis usadas em todas as abordagens preditivas.

Conjunto de Covariáveis	Variáveis de comportamento animal				
	TC	TB	VC	VB	CA
<i>Séries completas</i>					
Set 1	0 a -174 h	0 a -174 h	0 a -174 h	0 a -174 h	0 a -174 h
Set 2	-6 a -174 h	-6 a -174 h	-6 a -174 h	-6 a -174 h	-6 a -174 h
Set 3	-12 a -174 h	-12 a -174 h	-12 a -174 h	-12 a -174 h	-12 a -174 h
Set 7	0 a -24 h	0 a -24 h	0 a -24 h	0 a -24 h	0 a -24 h
Set 8	-6 a -24 h	-6 a -24 h	-6 a -24 h	-6 a -24 h	-6 a -24 h
Set 9	-12 a -24 h	-12 a -24 h	-12 a -24 h	-12 a -24 h	-12 a -24 h
<i>Séries s/CA</i>					
Set 4	0 a -174 h	0 a -174 h	0 a -174 h	0 a -174 h	-
Set 5	-6 a -174 h	-6 a -174 h	-6 a -174 h	-6 a -174 h	-
Set 6	-12 a -174 h	-12 a -174 h	-12 a -174 h	-12 a -174 h	-
Set 10	0 a -24 h	0 a -24 h	0 a -24 h	0 a -24 h	-
Set 11	-6 a -24 h	-6 a -24 h	-6 a -24 h	-6 a -24 h	-
Set 12	-12 a -24 h	-12 a -24 h	-12 a -24 h	-12 a -24 h	-

(TC) tempo no cocho, (TB) tempo no bebedouro, (VC) visitas ao cocho, (VA) visitas ao bebedouro, (CA) consumo alimentar.

Os procedimentos de *RL*, *ANN* e *RF* foram realizados no software de código aberto para análise de *big data* H2O (<https://cran.rproject.org/web/packages/h2o/h2o.pdf>) por meio do software estatístico R (R Core Team, 2016).

Em métodos de *Machining Learning*, como *ANN* e *RF*, o uso de hiperparâmetros devem ser otimizados, como forma de se tentar buscar a melhor arquitetura de ANN e RF. Devido a quantidade hiperparâmetros utilizados nestes métodos, uma busca para encontrar a melhor combinação foi realizada. A busca, denominada *grid search*, foi feita de maneira aleatória, dentro do espaço definido para cada hiperparâmetro (Tabela 4 e 5), utilizando a função *h2o.grid*, como descrito por Dórea et al. (2018). Após realizado o *grid search*, os hiperparâmetros para o melhor modelo foram escolhidos para cada conjunto de covariáveis (*Sets*).

Tabela 4. Espaço de hiperparâmetros e critérios de busca utilizados na busca de redes neurais artificiais (RNA). Os hypermeters foram combinados para encontrar a melhor estrutura de RNA.

Pesquisa de grade: hiperparâmetros e critérios de pesquisa				
Hiperparâmetros				
Função de Ativação	Camadas ocultas	Proporção de <i>dropout</i> de entrada	L1 ¹	L2 ²
<i>Rectifier</i>	2	0	0	0
<i>Tanh</i>	8	0.25	0.0001	0.0001
<i>Maxout</i>	20		0.000001	0.000001
<i>RectifierWithDropout</i>	40			
<i>TanhWithDropout</i>	50			
<i>MaxoutWithDropout</i>	60			
	80			
	100			
	110			
	120			
	130			
	150			
	20,20			
	50,50			
	30,30,30			
	25,25,25,25			
<i>Search criteria</i>				
Strategy	max_runtime_secs ⁴	max_models ⁵	stopping_metric ⁶	
RandomDiscrete ³	4000	300	Missclassification	

¹L1 = Lasso regularization

²L2 = Ridge regularization

³RandomDiscrete = pesquisa aleatória de todas as combinações de hiperparâmetros

⁴max_runtime_secs = Tempo de execução máximo em segundos para toda a pesquisa de grade

⁵max_models = número máximo de modelos pesquisados na grade

⁶stopping_metric = Função usada para parada antecipada com base em nenhuma melhoria na métrica do modelo (neste caso, métrica definida como RMSE)

Tabela 5. Espaço de hiperparâmetros e critérios de busca utilizados na busca da grade de *Random Forest* (RF).

Pesquisa de grade: hiperparâmetros			
Número de árvores	Número mínimo de observações em uma folha	Número de variáveis usadas em cada divisão	Profundidade Máxima da Árvore
10	1	1	1
20	2	2	10
40	10	3	20
100	20	4	40
200	30	5	80
Critérios de pesquisa			
Estratégia	max_runtime_secs ²	max_models ³	stopping_metric ⁴
RandomDiscrete ¹	4000	300	Missclassification

¹*RandomDiscrete* = pesquisa aleatória de todas as combinações de hiperparâmetros

²*max_runtime_secs* = tempo de execução máximo em segundos para toda a pesquisa de grade

³*max_models* = número máximo de modelos pesquisados na grade

⁴*stopping_metric* = Função usada para parada antecipada com base em nenhuma melhoria na métrica do modelo (neste caso, métrica definida como RMSE)


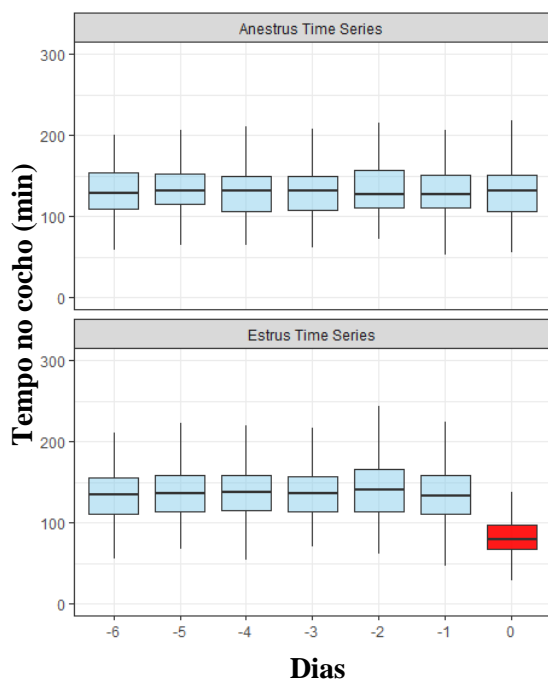
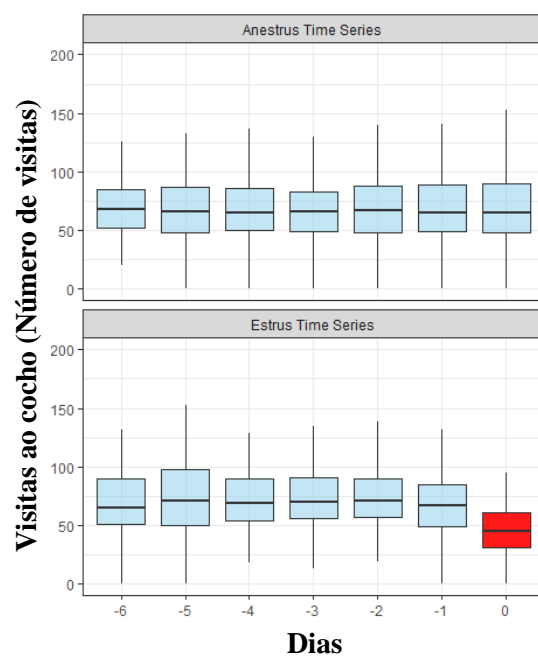

A validação do modelo foi realizada por meio da *Leave-One-Out Cross Validation* (LOOCV), na qual todos os registros relacionados a vaca foram excluídos e os demais registros de animais foram usados para treinar o modelo. Essa abordagem foi repetida n vezes até que todas as vacas fossem excluídas do conjunto de treinamento. Acurácia, sensibilidade, especificidade e intervalos de confiança de 95% foram calculados para classificação de animais como em Estro ou Anestro usando o pacote IVD Performance Add-In do SAS JMP.

IV - RESULTADOS E DISCUSSÃO

O estudo envolveu a avaliação de como o estro altera as variáveis de consumo e comportamento alimentar/hídrico obtidos em cochos e bebedouros eletrônicos. Posteriormente, foram desenvolvidos e avaliados modelos de detecção e detecção antecipada (6 e 12 h de antecedência) com base em variáveis obtidas em cochos e bebedouros eletrônicos.

Na avaliação de como o estro interfere no consumo e comportamento alimentar/hídrico, todas as variáveis apresentaram declínio significativo ($P < 0.05$) no dia do estro em comparação com os dias anteriores e com a série de anestro (VC = 34,3%, VB = 25,0%, CA = 26,1%, TC = 39,6% e TB = 49,3%) (Figura 1). A menor variação foi observada para VB (média de 4 visitas em anestro e 3 visitas no dia do estro), provavelmente pelo baixo número de visitas aos bebedouros ao longo do dia em comparação com o cocho de alimentação (média de 70 visitas em anestro e 46 visitas no dia do estro). Reith & Hoy (2017), também identificaram redução no consumo alimentar próximo ao estro de 14,6%, fato justificado pelo aumento na atividade de busca por parceiro de acasalamento (Kerbrat & Disenhaus, 2004). As variações no comportamento em torno do estro em fêmeas bovinas também foram relatadas (Silper et al., 2015; Gaillard et al., 2016) em estudos que adotaram dispositivos eletrônicos de monitoramento de atividade em colares e pedômetros.

As variações de consumo e comportamento alimentar obtidas nos cochos e bebedouros eletrônicos confirmam a hipótese “Cochos e bebedouros eletrônicos permitem identificar as variações no consumo e comportamento alimentar causadas pelo estro em novilhas leiteiras” e indicam a possibilidade de utilização dessas variáveis para detecção e detecção antecipada de estro em novilhas leiteiras. Assim, foram desenvolvidos e avaliados modelos de detecção e detecção antecipada de estro.






Figura 3. Variação no consumo e comportamento alimentar de novilhas no dia do estro monitoradas por cochos e bebedouros eletrônicos.

Os modelos envolvendo *ANN* e *RF* apresentaram sensibilidade, especificidade e acurácia satisfatórias ($> 90\%$) na detecção de estro usando a série temporal de -174h. Já os modelos de *RL* não puderam ser utilizados para os sets 1 a 6, por existirem mais variáveis que o número de observações de estro considerando a série temporal de -174 a -12, -6 ou 0 h. Assim, apenas os sets contendo observações das últimas 24 horas foram utilizados. Os métodos de *Machine Learning* em geral não possuem *assumptions*, como consideradas em métodos tradicionais (regressão logística e linear, por exemplo). Foram consideradas detecções satisfatórias para o presente estudo os modelos que atingiram acurácia e valores de sensibilidade e especificidade superiores a 90%. Para detecção antecipada com 6 ou 12 horas de antecedência, valores de acurácia superiores a 80% foram determinados como limite mínimo para garantir uma detecção promissora.

ANN e *RF* apresentaram valores elevados e próximos de sensibilidade, especificidade e acurácia (Set 1: 100, 92.0 e 95.9% para *ANN* e 100, 93.2 e 96.5% para *RF*, respectivamente). O desempenho satisfatório dos modelos para detecção do estro com dados de uma semana antes do estro é explicado pela capacidade dos modelos de *Machine Learning* aprenderem relações complexas entre entrada e saída de

informações, uma vez que, contêm múltiplas camadas ocultas não-lineares (Srivastava et al., 2014).

Dolecheck et al. (2015) encontraram valores superiores de sensibilidade, especificidade e acurácia usando modelos de *Machine Learning* para detecção do estro usando as tecnologias automatizadas de monitoramento *Cow Manager Sensor* (atividade e ruminação) e o *Ice-Qube* (pedômetro). Para os modelos de RF o *Cow Manager Sensor* e o *Ice-Qube* apresentaram 98,6% de sensibilidade, enquanto para ANN o *Ice-Qube* teve 100% de sensibilidade, no entanto, devido ao baixo número de eventos de observações de estro ($n = 18$), os autores sugeriram cautela nas interpretações.

Para detecção antecipada do estro (-6 e -12 h), os modelos apresentaram desempenho inferior aos de detecção (0 h). Para ANN, os modelos preditivos com 6 h de antecedência que se destacaram foram os sets 2, 8 e 11 que atingiram acurácias de 82,0, 88,4 e 82,1%, respectivamente. Para os modelos de RF, todos os sets (2, 5, 8 e 11) preditivos -6 e -12h (set 12) atingiram desempenho satisfatório de acurácia (84,3, 80,9, 81,0, 80,9 e 80,3% respectivamente). Na RL, apenas o modelo de detecção do estro -6h (Set 11) conseguiu atingir 80% de acurácia, limite mínimo considerado no presente trabalho para classificar como promissora a possibilidade de detectar com antecedência o estro. Aungier et al. (2015), também encontraram alterações no comportamento registrado pelo dispositivo Heatime® (SCR Engineers Ltd, Netanya, Israel) seis horas antes do estro, mas o dispositivo só conseguiu detectar o estro 3 horas após o início do aumento de atividade.

Esses resultados confirmam parcialmente a hipótese “modelos desenvolvidos por ANN, RF e RL são capazes de detectar com antecedência (com 6 ou 12 h de antecedência) e detectar o estro de novilhas leiteiras com base nas variáveis geradas por cochos e bebedouros eletrônicos”. A utilização de dispositivos com algoritmos desenvolvidos por *Machine Learning* que permitam a identificação precoce do estro pode possibilitar a antecipação de sinais de alerta de estro e garantir planejamento de execução de atividades na fazenda leiteira. Os modelos de detecção antecipada apresentaram redução nos valores de sensibilidade, especificidade e acurácia comparados com os modelos de detecção, provavelmente devido a maior variação da ingestão e comportamento alimentar/hídrico estar concentrada próximo ao estro, com isso ao excluir os dados de -6 e -12 a 0 h do estro, o comportamento das variáveis tenderam ao padrão normal de anestro, limitando a detecção antecipada do estro.

Os modelos de *ANN* e *RF* para detecção de estro utilizando a série temporal de 24 horas antes do estro também apresentaram valores de sensibilidade, especificidade e acurácia superiores ou próximos a 90% (Set 7: 100, 93.2 e 96.5% para *ANN* e 98.8, 89.8 e 94.2% para *RF* respectivamente), o que confirma a hipótese de que “dados de séries temporais de 24 horas são suficientes para detecção e predição do estro, não sendo necessário a utilização de dados de uma semana (174 h)”. Esse resultado pode ser explicado em nosso estudo pelo baixo nível de complexidade do conjunto de dados, já que as variáveis de consumo e comportamento alimentar/hídrico se correlacionam e foram extraídas de tecnologia única, os cochos e bebedouros eletrônicos.

Todos os modelos de detecção (0 a -24h e 0 a -174h) analisados, com e sem a variável de consumo alimentar, apresentaram pouca variação de sensibilidade, especificidade e acurácia, o que confirma a hipótese “é possível detectar e detectar com antecedência o estro somente com dados de comportamento alimentar”, não sendo necessário os dados de consumo alimentar, variável que geralmente é mais cara e difícil de ser obtida. Embora os modelos de *Machine Learning e Regressão logística* não forneçam necessariamente a explicação biológica para a relação entre variáveis de detecção (consumo e comportamento alimentar/hídrico) e resposta (estro), o reconhecimento de padrões e as capacidades de detecção e detecção antecipada são fatores-chave para conduzir análises de conjuntos de dados de forma precisa (Dórea et al., 2018). A acurácia, sensibilidade e especificidade dos modelos gerados indicam a possibilidade da inclusão de lógica nos sistemas de cochos e bebedouros eletrônicos que permitirão a detecção do estro em bovinos leiteiros.

Tabela 6. Sensibilidade, especificidade, acurácia, valores preditos positivos (VPP), valores preditos negativos (VPN) para diferentes abordagens preditivas e conjuntos de covariáveis.

Conjunto de covariáveis (sets*)	Sensibilidade (%) [95% CI]	Especificidade e (%) [95% CI]	Acurácia (%) [95% CI]	PPV (%) [95% CI]	NPV (%) [95% CI]
<i>Regressão Logística</i>					
Set 7	100 [95.7 – 100]	86.4 [77.7 – 92.0]	93.0 [88.2 – 96.3]	87.6 [79.6 – 92.8]	100 [95.2 – 100]
Set 8	91.8 [84.0 – 96.0]	61.4 [50.9 – 70.9]	76.3 [69.2 – 82.4]	69.6 [60.6 – 77.4]	88.5 [78.2 – 94.3]
Set 9	90.6 [82.5 – 95.2]	48.9 [38.7 – 59.1]	69.3 [61.9 – 76.1]	63.1 [54.3 – 71.2]	84.3 [72.0 – 91.8]
Set 10	100 [95.7 – 100]	88.6 [80.3 – 93.7]	94.2 [89.6 – 97.2]	89.5 [81.7 – 94.2]	100 [95.3 – 100]
Set 11	90.6 [82.5 – 95.2]	70.5 [60.2 – 79.0]	80.3 [73.3 – 85.0]	74.8 [65.6 – 82.2]	88.6 [79.0 – 94.1]

Set 12	88.2 [79.7 – 93.5]	53.4 [43.1 – 63.5]	70.5 [67.4 – 80.1]	64.7 [55.6 – 72.8]	82.5 [70.6 – 90.2]
<i>Artificial Neural Network</i>					
Set 1	100 [95.7 – 100]	92.0 [84.5 – 96.1]	95.9 [90.4 – 96.3]	92.4 [85.1 – 96.3]	100 [95.5 – 100]
Set 2	85.9 [76.9 – 91.7]	78.4 [68.7 – 85.7]	82.0 [74.4 – 86.3]	79.3 [70.0 – 86.4]	85.2 [75.9 – 91.3]
Set 3	95.3 [88.5 – 98.2]	62.5 [52.1 – 71.9]	78.6 [74.8 – 86.2]	71.1 [62.1 – 78.6]	93.2 [83.8 – 97.3]
Set 4	98.8 [96.6 – 99.8]	90.9 [83.1 – 95.3]	94.7 [89.2 – 97.4]	91.3 [83.8 – 95.5]	98.8 [93.3 – 99.8]
Set 5	95.3 [88.5 – 98.2]	63.6 [53.2 – 72.9]	79.1 [72.2 – 87.5]	71.7 [62.8 – 79.2]	93.3 [84.1 – 97.4]
Set 6	94.1 [87.0 – 97.5]	58.0 [47.5 – 67.7]	75.7 [69.9 – 85.7]	68.4 [59.5 – 76.1]	91.1 [80.7 – 96.1]
Set 7	100 [95.7 – 100]	93.2 [85.9 – 96.8]	96.5 [90.3 – 97.6]	93.4 [86.4 – 96.9]	100 [95.5 – 100]
Set 8	92.9 [85.4 – 96.7]	84.1 [75.0 – 90.3]	88.4 [80.2 – 95.4]	84.9 [76.3 – 90.8]	92.5 [84.6 – 96.5]
Set 9	89.4 [81.1 – 94.3]	69.3 [59.0 – 78.0]	79.1 [72.1 – 86.3]	73.8 [64.5 – 81.3]	87.1 [77.3 – 93.1]
Set 10	98.8 [93.6 – 99.8]	94.3 [87.4 – 97.5]	96.5 [91.4 – 97.8]	94.4 [87.5 – 97.6]	98.8 [93.6 – 99.8]
Set 11	94.1 [87.0 – 97.5]	70.5 [60.2 – 79.0]	82.1 [71.1 – 86.4]	75.5 [66.5 – 82.7]	92.5 [83.7 – 96.8]
Set 12	91.8 [84.0 – 96.0]	63.6 [53.2 – 72.9]	77.4 [68.8 – 85.4]	70.9 [61.8 – 78.6]	88.9 [78.8 – 94.6]
<i>Random Forest</i>					
Set 1	100 [95.7 - 100]	93.2 [85.9 – 96.8]	96.5 [91.2 – 97.1]	93.4 [86.4 – 96.9]	100 [95.5 – 100]
Set 2	97.6 [91.8 - 99.4]	71.6 [61.4 – 80.0]	84.3 [75.2 – 89.8]	76.9 [68.1 – 83.8]	96.9 [89.5 – 99.2]
Set 3	94.1 [87.0 - 97.5]	65.9 [55.5 – 75.0]	79.7 [71.3 – 87.8]	72.7 [63.7 – 80.2]	92.1 [82.7 – 96.6]
Set 4	100 [95.7 – 100]	90.9 [83.1 – 95.3]	95.3 [89.9 – 97.4]	91.4 [83.9 – 95.6]	100 [95.4 – 100]
Set 5	97.6 [91.8 - 99.4]	64.8 [54.4 – 73.9]	81.0 [70.1 – 87.0]	72.8 [64.0 – 80.1]	96.6 [88.5 – 99.1]
Set 6	96.6 [92.8 - 99.2]	55.7 [45.3 – 65.6]	76.3 [67.4 – 84.4]	68.0 [59.3 – 75.6]	96.1 [86.8 – 98.9]
Set 7	98.8 [93.6 - 99.8]	89.8 [81.7 – 94.5]	94.2 [90.2 – 96.4]	90.3 [82.6 – 94.8]	98.8 [93.3 – 99.8]
Set 8	98.8 [93.6 – 99.8]	63.6 [53.2 – 72.9]	80.9 [72.0 – 86.7]	72.4 [63.7 – 79.7]	98.2 [90.7 – 99.7]
Set 9	92.9 [85.4 – 96.7]	61.4 [50.9 – 70.9]	76.8 [67.4 – 84.3]	69.9 [60.9 – 77.6]	90.0 [79.9 – 95.3]
Set 10	98.8 [93.6 – 99.8]	83.0 [73.8 – 89.4]	90.7 [88.4 – 96.1]	84.8 [76.5 – 90.6]	98.6 [92.7 – 99.8]
Set 11	96.5 [90.1 - 98.8]	65.9 [55.5 – 75.0]	80.9 [74.9 – 86.9]	73.2 [64.3 – 80.5]	95.1 [86.5 – 98.3]
Set 12	95.3	65.9	80.3	73.0	93.5

[88.5 – 98.2] [55.5 – 75.0] [74.8 – 87.3] [64.0 – 80.4] [84.6 – 97.5]

* Conjunto de covariáveis (sets) = Set 1) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal a partir do tempo (t) = 0 a -174 h; Set 2) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal t = -6 a -174 h; Set 3) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal t = -12 até -174 h; Set 4) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal t = 0 a -174 h; Set 5) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal t = -6 a -174 h; Set 6) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal t = -12 a -174 h; Set 7) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal t = 0 a -24h); Set 8) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal t = -6 a -24h; Set 9) Variáveis de consumo e comportamento alimentar/hídrico utilizando série temporal t = -12 a -24h; Set 10) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal t = 0 a -24); Set 11) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal t = -6 a -24); Set 12) Utilização somente de variáveis de comportamento alimentar/hídrico utilizando série temporal de t = -12 a -24

V - CONCLUSÃO

Cochos e bebedouros eletrônicos permitem identificar as variações no consumo e comportamento alimentar/hídrico causadas pelo estro em novilhas leiteiras. Modelos desenvolvidos por *Regressão Logística* ou métodos de *Machine Learning* são capazes de detectar estro de novilhas leiteiras, com base nas variáveis geradas por cochos e bebedouros eletrônicos, confirmando a possibilidade de inclusão da funcionalidade detecção de estro nesses dispositivos. Modelos ANN, RF e RL são promissores para detectar o estro com 6 horas de antecedência. A série temporal de 24 h antes do estro é suficiente para a detecção acurada e precisa do estro com base em dados de cochos e bebedouros eletrônicos. A exclusão de dados de consumo alimentar não reduz de forma significativa a acurácia, sensibilidade e especificidade de modelos para detecção de estro, evidenciando a possibilidade de desenvolvimento de novos dispositivos com base em sensores, que permitam a identificação de variações do comportamento alimentar/hídrico causado pelo estro.

VI - REFERÊNCIAS

AUNGIER, S. P. M., J. F. ROCHE, P. DUFFY, S. SCULLY, AND M. A. CROWE. The relationship between activity clusters detected by an automatic activity monitor and endocrine changes during the periestrus period in lactating dairy cows. **Journal of Dairy Science**. 98:1666–1684, 2015.

CHIZZOTTI, M. L., MACHADO, F. S., VALENTE, E. E. L., PEREIRA, L. G. R., CAMPOS, M. M., TOMICH, T. R., ... RIBAS, M. N. Technical note : Validation of a system for monitoring individual feeding behavior and individual feed intake in dairy cattle. **Journal of Dairy Science**, 98(5), 3438–3442, 2015. <https://doi.org/10.3168/jds.2014-8925>

DOLECHECK, K. A., SILVIA, W. J., HEERSCHKE, G., CHANG, Y. M., RAY, D. L., STONE, A. E., ... BEWLEY, J. M. Behavioral and physiological changes around estrus events identified using multiple automated monitoring technologies. **Journal of Dairy Science**, 98(12), 8723–8731, 2015. <https://doi.org/10.3168/jds.2015-9645>

DÓREA, J. R. R., ROSA, G. J. M., WELD, K. A., & ARMENTANO, L. E. Mining data from milk infrared spectroscopy to improve feed intake predictions in lactating dairy cows. **Journal of Dairy Science**, 1–12, 2018. <https://doi.org/10.3168/jds.2017-13997>

GAILLARD C, BARBU M, SØRENSEN T, SEHESTED J, CALLESEN H AND VESTERGAARD M. Milk yield and estrous behavior during eight consecutive estruses in Holstein cows fed standardized or high energy diets and grouped according to live weight changes in early lactation. **Journal of Dairy Science** 99, 3134–3143, 2016.

GIANOLA, D., H. OKUT, K. A. WEIGEL, AND G. J. M. ROSA. Predicting complex quantitative traits with Bayesian neural networks: A case study with Jersey cows and wheat. **BMC Genet**. 12:87–99, 2011. <https://doi.org/10.1186/1471-2156-12-87>.

HEMPSTALK, K., MCPARLAND, S., & BERRY, D. P. Machine learning algorithms for the prediction of conception success to a given insemination in lactating dairy cows. **Journal of Dairy Science** 98(8), 5262–5273, 2015. <https://doi.org/10.3168/jds.2014-8984>

HIGAKI, S., MIURA, R., SUDA, T., ANDERSSON, L. M., OKADA, H., ZHANG, Y., YOSHIOKA, K. Estrous detection by continuous measurements of vaginal temperature and conductivity with supervised machine learning in cattle. **Theriogenology**. 2018 <https://doi.org/10.1016/j.theriogenology.2018.09.038>

KERBRAT, S., AND C. DISENHAUS. A proposition for an updated behavioral characterisation of the oestrus period in dairy cows. **Appl. Anim. Behav. Sci.** 87:223–238, 2004.

LEÃO JULIANA,. Uso da termografia infravermelha na pecuária de precisão. **Appl. Anim. Behav. Sci** 97–109, 2015.

PAHL, C., HARTUNG, E., MAHLKOW-NERGE, K., & HAEUSSERMANN, A.. Feeding characteristics and rumination time of dairy cows around estrus. **Journal of Dairy Science**, 98(1), 148–154, 2015. <https://doi.org/10.3168/jds.2014-8025>

POLSKY, L. B., MADUREIRA, A. M. L., FILHO, E. L. D., SORIANO, S., SICA, A. F., VASCONCELOS, J. L. M., & CERRI, R. L. A. Association between ambient temperature and humidity, vaginal temperature, and automatic activity monitoring on induced estrus in lactating cows. **Journal of Dairy Science**, 100(10), 8590–8601, 2017. <https://doi.org/10.3168/jds.2017-12656>

REITH, S., M. PRIES, C. VERHUELSDONK, H. BRANDT, AND S. HOY. Influence of estrus on dry matter intake, water intake, and BW of dairy cows. **Animal** 8:748–753, 2014.

REITH, S., & HOY, S. Review : Behavioral signs of estrus and the potential of fully automated systems for detection of estrus in dairy cattle, **Journal of Dairy Science** 1–10, 2017. <https://doi.org/10.1017/S1751731117001975>

ROELOFS, J. B., E. G. BOUWMAN, S. J. DIELEMAN, F. J. C. M. VAN EERDENBURG, L. M. T. E. KAAL-LANSBERGEN, N. M. SOEDE, AND B. KEMP. Influence of repeated rectal ultrasound examinations on hormone profiles and behaviour around oestrus and ovulation in dairy cattle. **Theriogenology** 62:1337–1352, 2004. <http://dx.doi.org/10.1016/j.theriogenology.2004.02.002>.

RÖTTGEN, V., BECKER, F., TUCHSCHERER, A., WRENZYCKI, C., DÜPJAN, S., SCHÖN, P. C., & PUPPE, B. Vocalization as an indicator of estrus climax in Holstein heifers during natural estrus and superovulation. **Journal of Dairy Science**, (1), 2383–2394, 2018. <https://doi.org/10.3168/jds.2017-13412>

SILPER, B. F., MADUREIRA, A. M. L., KAUR, M., BURNETT, T. A., & CERRI, R. L. A. Short communication: Comparison of estrus characteristics in Holstein heifers by 2 activity monitoring systems. **Journal of Dairy Science**, 98(5), 3158–3165, 2015. <https://doi.org/10.3168/jds.2014-9185>

SRIVASTAVA N, HINTON G, KRIZHEVSKY A, SUTSKEVER I, SALAKHUTDINOV R. Dropout: a simple way to prevent neural networks from overfitting. **JMac Learn Res** 15: 1929 – 1958, 2014.

THOMPSON, A. J., WEARY, D. M., & KEYSERLINGK, M. A. G. VON. Technical note : Mining data from on-farm electronic equipment to identify the time dairy cows spend away from the pen. **Journal of Dairy Science**, 100(5), 3975–3982, 2017. <https://doi.org/10.3168/jds.2016-11713>

WEIGEL, K. A., VANRADEN, P. M., NORMAN, H. D., & GROSU, H.. A 100-Year Review : Methods and impact of genetic selection in dairy cattle — From daughter – dam comparisons to deep learning algorithms 1, **Journal of Dairy Science** 10234–10250, 2017. <https://doi.org/10.3168/jds.2017-12954>