

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
ESCOLA DE ENGENHARIA
PROGRAMA DE PÓS-GRADUAÇÃO EM ENGENHARIA ELÉTRICA

YURI DAS NEVES VALADÃO

**SISTEMA DE MONITORAMENTO DO
COMPORTAMENTO DE BOVINOS POR
MEIO DE REDES DE SENSORES SEM
FIO**

Porto Alegre
2021

YURI DAS NEVES VALADÃO

**SISTEMA DE MONITORAMENTO DO
COMPORTAMENTO DE BOVINOS POR
MEIO DE REDES DE SENSORES SEM
FIO**

Dissertação de mestrado apresentada ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul como parte dos requisitos para a obtenção do título de Mestre em Engenharia Elétrica.

Área de concentração: Controle e Automação

ORIENTADOR: Prof. Dr. Ivan Müller

Porto Alegre
2021

YURI DAS NEVES VALADÃO

**SISTEMA DE MONITORAMENTO DO
COMPORTAMENTO DE BOVINOS POR
MEIO DE REDES DE SENSORES SEM
FIO**

Esta dissertação foi julgada adequada para a obtenção do título de Mestre em Engenharia Elétrica e aprovada em sua forma final pelo Orientador e pela Banca Examinadora.

Orientador: _____
Prof. Dr. Ivan Müller, UFRGS
Doutor pela Universidade Federal do Rio Grande do Sul –
Porto Alegre, Brasil

Banca Examinadora:

Prof. Dr. Hamilton Duarte Klimach, UFRGS
Doutor pela Universidade Federal de Santa Catarina – Florianópolis - SC, Brasil

Prof. Dr. Sebastian Yuri Cavalcanti Catunda, UFRN
Doutor pela Universidade Federal de Campina Grande – Campina Grande - PB,
Brasil

Prof. Dr. Valner João Brusamarello, UFRGS
Doutor pela Universidade Federal de Santa Catarina – Florianópolis - SC, Brasil

Coordenador do PPGEE: _____
Dr. Sérgio Luís Haffner

Porto Alegre, Abril de 2021.

DEDICATÓRIA

Aos meus pais, Tânia e Cleimar, e a minha noiva, Flávia.

AGRADECIMENTOS

A dedicação deste trabalho ocorreu, principalmente, pelo auxílio e compreensão de várias pessoas. Agradeço a todos que de alguma forma contribuíram para conclusão deste trabalho, e, de maneira especial, agradeço:

- ao meu orientador, professor Ivan Müller, pela oportunidade, por todo apoio e incentivo durante a realização do trabalho;

- ao Programa de Pós-Graduação em Engenharia Elétrica da Universidade Federal do Rio Grande do Sul;

- aos meus pais, Tânia e Cleimar, e ao meu irmão Igor, por todo apoio durante a minha trajetória acadêmica;

- a minha noiva Flávia Schneider, por toda paciência, apoio e compreensão durante a realização deste trabalho;

- ao meu amigo Bruno Fontana, pela amizade nesses anos todos, além de todo apoio e conversas, que convergiram para realização deste trabalho;

- ao meu amigo Daniel Bertineti, pela parceria ao longos desses anos, pelas ajudas com as imagens deste trabalho e, principalmente, pelo momentos de conversas e discussões durante a realização deste trabalho;

- ao meu amigo Max Feldman, pelo apoio e discussões necessárias para realização deste trabalho;

- ao colegas de LASCAR, pelo apoio durante a realização deste trabalho;

- ao veterinário Sílvio Renato Oliveira Menegassi, pela demanda da proposta do trabalho, assim como todo auxílio na realização dos testes de campo;

- a empresa Joape, principalmente na figura do Sr. João Henrique Schmidt dos Santos, pelo desenvolvimento dos protótipos dos invólucros utilizados.

RESUMO

Com o crescimento constante da pecuária de precisão, novos estudos com intuito de monitoramento de atividade dos animais crescem consideravelmente. Observar a atividade de reprodução de rebanhos é de suma importância para maximizar a cadeia produtiva, reduzindo a necessidade de inseminação artificial e os problemas relacionados a ela. O presente trabalho propõe o desenvolvimento de dispositivos para detecção do comportamento reprodutivo dos bovinos, propondo uma rede de sensores sem fio. Os dispositivos são afixados aos animais, com capacidade de detecção de movimentos e temperatura dos animais, disponibilizando os dados para algoritmos de identificação dos eventos, principalmente reprodutivos. Os algoritmos incluem técnicas de *machine learning*, buscando a identificação dos eventos, avaliando vários cenários quanto aos diferentes tipos de recorte dos dados. Os resultados mostram que os modelos podem alcançar sensibilidade média de 97,75% na detecção do evento.

Palavras-chave: Redes de Sensores sem Fio, Monitoramento Animal, Detecção de Eventos em Séries Temporais, *Machine Learning*, Aprendizagem Supervisionada.

ABSTRACT

The constant growth of precision livestock, new studies aiming at monitoring animal activity are growing considerably. Observing the activity of breeding herds is extremely important to maximize the production chain, reducing the need for artificial insemination and the problems related to it. The present work proposes the development of devices for the detection of bovine reproductive behavior, proposing a wireless sensor network. The devices are attached to animals, with the ability to detect animal movements and temperatures, saving data for training and identification of events, mainly reproductive. From these data, machine learning techniques are employed, seeking to identify the events, evaluating various scenarios as to the different types of data clipping. The results show that the models can achieve an average recall of 97.75 % in event detection.

Keywords: Wireless Sensor Network, Animal Monitoring, Time Series Event Detection, Machine Learning, Supervised Learning.

LISTA DE ILUSTRAÇÕES

Figura 1 –	Exemplo de RSSF.	19
Figura 2 –	Exemplo de RSSF: utilização em monitoramento animal.	19
Figura 3 –	Imagem microscópica de um acelerômetro.	21
Figura 4 –	Estrutura interna de um giroscópio MEMS.	22
Figura 5 –	Estrutura de um magnetômetro.	23
Figura 6 –	Função Sigmóide - Curva característica da Regressão Logística.	27
Figura 7 –	Exemplo de uma estrutura de Árvore.	28
Figura 8 –	Exemplo do funcionamento do SVC, (a) busca dos vetores, (b) ampliação da margem	30
Figura 9 –	Sistema para detecção da cópula de ovinos, através de sensores vestíveis nos machos (a), que se comunicam com sensores RFID passivos no dorso das fêmeas (b).	36
Figura 10 –	Sistema para detecção da cópula, sensores na cauda da fêmea e no dorso no macho.	36
Figura 11 –	Diagrama pictórico do sistema proposto.	40
Figura 12 –	Diagrama de sequência da comunicação.	41
Figura 13 –	Invólucro utilizado para o dispositivo intravaginal.	42
Figura 14 –	Placa de desenvolvimento LoRa SX1276.	43
Figura 15 –	Placa de desenvolvimento MPU - 9052.	44
Figura 16 –	Diagrama do dispositivo.	45
Figura 17 –	Placa desenvolvida (vista superior).	45
Figura 18 –	Placa desenvolvida (vista inferior).	46
Figura 19 –	Máquina de estado do microcontrolador.	47
Figura 20 –	Exemplo de publicação do dispositivo na rede.	47
Figura 21 –	Interface de configuração de dispositivo na rede.	49
Figura 22 –	Modelo de pacote de comunicação inicialmente proposto para os dados dos sensores.	50
Figura 23 –	Modelo do pacote de comunicação adotado para o sistema proposto.	51
Figura 24 –	Exemplo de visualização da sincronização dos dados.	52
Figura 25 –	Recorte do <i>dataset</i> organizado.	53
Figura 26 –	Janelamento dos dados do <i>dataset</i>	56
Figura 27 –	Exemplo de identificação de evento de reprodução através dos dados obtidos pelo sistema proposto.	57
Figura 28 –	Hardware antigo no DIV aberto.	61
Figura 29 –	Recorte temporal dos dados, unindo sensor do macho e DIV.	61
Figura 30 –	Recorte temporal dos dados, unindo sensor da fêmea e DIV.	62
Figura 31 –	Foto dos testes realizados em Júlio de Castilhos.	63

Figura 32 – Foto do colar utilizado nos testes da UFRGS.	64
Figura 33 – Monta sem identificação do macho - Dados do giroscópio.	65
Figura 34 – Monta sem identificação do macho - Dados do acelerômetro.	65
Figura 35 – Monta identificada 1 - Dados do giroscópio.	66
Figura 36 – Monta identificada 1 - Dados do acelerômetro.	66
Figura 37 – Monta identificada 2 - Dados do giroscópio.	67
Figura 38 – Monta identificada 2 - Dados do acelerômetro.	67
Figura 39 – Histograma da sensibilidade dos modelos considerando todos elementos.	68
Figura 40 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando todos elementos.	69
Figura 41 – Histograma da sensibilidade dos modelos considerando todos elementos mais valores absolutos.	70
Figura 42 – Histograma da sensibilidade dos modelos considerando todos elementos com valores absolutos.	71
Figura 43 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando todos elementos com valores absolutos.	72
Figura 44 – Histograma da sensibilidade dos modelos considerando valores absolutos sem dados de temperatura.	73
Figura 45 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando valores absolutos sem dados de temperatura.	73
Figura 46 – Histograma da sensibilidade dos modelos considerando apenas giroscópio e acelerômetro.	74
Figura 47 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando apenas giroscópio e acelerômetro.	75
Figura 48 – Histograma da sensibilidade dos modelos considerando apenas valores absolutos de giroscópio e acelerômetro.	75
Figura 49 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando apenas valores absolutos de giroscópio e acelerômetro.	76
Figura 50 – Histograma da sensibilidade dos modelos com janela de dados para 2,5 segundos e passo de 1 segundo.	78
Figura 51 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 2,5 segundos e passo de 1 segundo.	78
Figura 52 – Histograma da sensibilidade dos modelos com janela de dados para 5 segundos e passo de 1 segundo.	79
Figura 53 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 5 segundos e passo de 1 segundo.	79
Figura 54 – Histograma da sensibilidade dos modelos com janela de dados para 0,5 segundos e passo de 0,5 segundos.	80
Figura 55 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 0,5 segundos e passo de 0,5 segundos.	81
Figura 56 – Histograma da sensibilidade no evento sem adição de eventos no treinamento.	82
Figura 57 – Histograma da sensibilidade no evento com adição de 10 eventos no treinamento.	83
Figura 58 – Histograma da sensibilidade no evento com adição de 25 eventos no treinamento.	83

Figura 59 – Histograma da sensibilidade no evento com adição de 75 eventos no treinamento.	84
Figura 60 – Histograma da sensibilidade no evento com peso de 40% para classe 1.	85
Figura 61 – Histograma da sensibilidade no evento com peso de 50% para classe 1.	86
Figura 62 – Histograma da sensibilidade no evento com peso de 60% para classe 1.	86
Figura 63 – Histograma da sensibilidade no evento com peso de 95% para classe 1.	87
Figura 64 – Histograma da sensibilidade sem inclusão do DIV.	88
Figura 65 – Diagrama de caixas da taxa de falsos positivos sem inclusão do DIV. .	89

LISTA DE TABELAS

Tabela 1 –	Variáveis Independentes vs Variável Dependentes.	25
Tabela 2 –	Trabalhos relacionados (resumo).	38
Tabela 3 –	Descrição dos principais eventos.	64
Tabela 4 –	Sensibilidade dos modelos conforme seleção das variáveis de entrada.	77
Tabela 5 –	Sensibilidade dos modelos conforme do janelamento dos dados.	81
Tabela 6 –	Sensibilidade dos modelos conforme inclusão de eventos de reprodução para treinamento.	84
Tabela 7 –	Sensibilidade dos modelos conforme alteração no peso da classe do evento.	87

LISTA DE ABREVIATURAS

CI	Circuito Integrado
DIV	Dispositivo Intravaginal
FFT	<i>Fast Fourier Transform</i>
I ² C	<i>Inter-Integrated Circuit</i>
IoT	<i>Internet of things</i>
LSTM	<i>Long Short-Term Memory</i>
MEMS	<i>MicroElectroMechanical System</i>
MIPS	Milhão de Instruções por Segundo
RF	Rádio Frequência
RFE	<i>Recursive Feature Elimination</i>
RFiD	<i>Radio Frequency Identifier</i>
RSSF	Redes de sensores sem fio
RTC	<i>Real Time Clock</i>
SPI	<i>Serial Peripheral Interface</i>
SVC	<i>Support vector classifier</i>
UART	<i>Universal Asynchronounous Receiver/Transmitter</i>

SUMÁRIO

1	INTRODUÇÃO	15
1.1	Motivação	16
1.2	Objetivos	16
2	FUNDAMENTAÇÃO TEÓRICA	18
2.1	Redes de Sensores sem Fio	18
2.2	Sensores	20
2.2.1	Micro Electro Mechanical System (MEMS)	20
2.2.2	Sensor de Temperatura	23
2.3	Aprendizagem de Máquina	23
2.3.1	<i>Dataset</i> Rotulado	24
2.3.2	Classificação Binária	24
2.3.3	Aprendizagem Supervisionada	25
2.3.4	Avaliação de Desempenho	30
3	ANÁLISE DO ESTADO DA ARTE	33
3.1	Detecção de Movimento em Seres Humanos	33
3.2	Sistemas para Monitoramento Animal	35
3.3	Resumo	38
4	SISTEMA PROPOSTO	39
4.1	Proposta	39
4.2	Desenvolvimento do Dispositivo	41
4.2.1	Elementos de Hardware	42

4.2.2	Dispositivo completo	45
4.3	Comunicação em Rede	46
4.4	Aquisição dos Dados	48
4.4.1	Configurações	48
4.4.2	Ciclo de Aquisição	49
4.4.3	Organização dos dados	49
4.4.4	Sincronização dos Dados	51
4.4.5	<i>Dataset</i> Organizado	52
4.5	Identificação dos Eventos	53
4.5.1	Interpolação dos Dados	54
4.5.2	Pré Processamento	54
4.5.3	Janelamento dos Dados	55
4.5.4	Rotulamento dos eventos de reprodução	56
4.5.5	Inserção de Casos	57
4.5.6	Utilização dos Métodos	58
5	ESTUDO DE CASO	60
5.1	Testes Iniciais	60
5.2	Análises Iniciais	62
5.3	Seleção de Variáveis de Entrada	67
5.3.1	Cenário 1 - Dados originais	68
5.3.2	Cenário 2 - Adição de valores absolutos	69
5.3.3	Cenário 3 - Utilização apenas de valores absolutos	70
5.3.4	Cenário 4 - Exclusão dos dados de temperatura	72
5.3.5	Cenário 5 - Utilização apenas de giroscópio e acelerômetro	74
5.3.6	Resumo das Seleção das Variáveis de Entrada	76
5.4	Alterações no Processamento dos dados	77
5.4.1	Mudanças no Janelamento dos Dados	77
5.4.2	Alteração na Quantidade de Eventos de Reprodução	81
5.4.3	Alteração no Peso das Classes	84
5.5	Alterações nos Indivíduos Observados	88

6	CONCLUSÕES	90
6.1	Contribuições da Dissertação	91
6.2	Trabalhos Futuros	91
	REFERÊNCIAS	93

1 INTRODUÇÃO

O agronegócio tornou-se um dos setores mais importantes da economia brasileira nas últimas décadas. Em 2019, representou cerca de 21% do Produto Interno Bruto (PIB) brasileiro, onde, aproximadamente 23% desta fatia é referente a produção agropecuária (SOENDERGAARD *et al.*, 2020). O significado da agropecuária se estende para economia mundial, realçando a importância de promover estudos de novas tecnologias ou aperfeiçoamento de técnicas nesse setor. Neste contexto tem-se a chamada pecuária de precisão, cujo intuito é a melhoria constante dos métodos de produção agropecuária. Estes estudos e tecnologias visam otimizar os resultados do processo, avaliando-os de forma qualitativa e quantitativa, direcionada à sustentabilidade. Quando realizada com animais de grande porte, como os bovinos, a pecuária de precisão pode ser utilizada para monitoramento de cada animal, possibilitando criar uma base de dados dos rebanhos, dados de cópulas e de saúde dos animais. Esses dados favorecem a percepção sobre a necessidade de adequações no manejo ambiental ou de intervenções sobre os animais, para que estes expressem toda sua capacidade produtiva.

Os principais objetivos da coleta de dados são a otimização do sistema de produção e a manutenção do bem-estar animal. Os dados permitem a avaliação do comportamento bovino, envolvendo a mensuração do tempo de desenvolvimento das atividades de ingestão de alimentos, ruminação e ócio, bem como informações sobre procriação, como fêmeas no cio, machos ativos e cruzas em campo (GARCIA *et al.*, 2018).

Desta forma, é necessário aprofundar os estudos na pecuária de precisão voltados a solucionar problemas e, ainda, com a possibilidade de melhorar os índices produtivos. À vista disso, a utilização de Rede de Sensores sem Fio (RSSF), com dispositivos agregados aos animais, fornece dados de monitoramento que podem ser utilizados para a otimização dos processos relacionados com a criação de animais.

Assim sendo, a proposta deste trabalho é monitorar o comportamento de animais de interesse através de uma RSSF. Com os nodos da rede instalados junto ao corpo dos animais é possível monitorar o comportamento destes, indicando problemas com cada indivíduo ou, ainda, possibilitando a identificação da paternidade na reprodução, identificando cópulas no rebanho e os agentes envolvidos nesses cruzamentos.

1.1 Motivação

O intuito do monitoramento animal é melhorar a eficiência do processo produtivo da pecuária, ou seja, otimizar a reprodução animal. Muito dessa otimização é obtida a partir da inseminação artificial em rebanhos. Contudo, esta técnica apresenta muitos problemas que comprometem a eficácia deste processo, como a ineficiência na detecção do estro, ou seja, o ciclo de reprodução animal, ou ainda o longo prazo para reprodução no período pós-parto (BARUSELLI *et al.*, 2012). Portanto, uma forma importante de monitoramento de rebanho pode acontecer através da observação do ciclo estral e a utilização de cópula em campo aberto para a reprodução. Contudo em, MENEGASSI *et al.* (2011), os autores alertam para o fato de que algumas raças bovinas possuem dificuldades em cópula em ambientes confinados ou, ainda, não realizam o ato quando sentem-se vigiadas e/ou monitoradas por seres humanos, portanto, surge a necessidade do monitoramento animal à distância.

O presente trabalho tem o intuito de prover métodos e materiais para monitorar bovinos à distância, principalmente no que tange a informações quanto à reprodução. Para tal, é implementada uma RSSF, cujo objetivo é capturar os dados necessários de cada indivíduo com intuito da identificação da cópula.

1.2 Objetivos

Este trabalho apresenta o objetivo geral de desenvolver as ferramentas necessárias para que seja possível o monitoramento e análise automática do comportamento animal, reconhecendo um comportamento rotineiro para melhorar o controle da reprodução dos mesmos. Isso deverá ocorrer com mínima intervenção humana, através da utilização de uma RSSF, capaz obter os dados dos sensores instalados em machos e fêmeas.

Para atingir este objetivo, a RSSF irá concentrar os dados e utilizar técnicas de apren-

dizagem supervisionada para a identificação do evento de interesse. Serão avaliados quatro métodos de aprendizagem supervisionada: Regressão Logística; Classificação Bayesiana Gaussiana; Classificador em Árvore de Decisão; Classificador com Vetores de Suporte. A partir desses classificadores, a intenção é estabelecer o melhor método para identificação do comportamento reprodutivo dos animais.

Objetivos específicos deste trabalho são:

- Estabelecer um hardware com capacidade de integrar os sensores e o rádio de comunicação, através de um microcontrolador;
- Desenvolver um *firmware* capaz de adquirir os dados dos sensores estabelecidos, e enviá-los para o sistema concentrador através de um enlace de comunicação entre os nodos;
- Escolher a melhor técnica que possa conectar a melhor relação entre esforço computacional e eficiência na detecção dos movimentos desejados;

Este trabalho está organizado da seguinte forma. No Capítulo 2 são apresentados os conceitos básicos utilizados ao longo da dissertação. No Capítulo 3 é apresentada uma revisão bibliográfica referente aos principais trabalhos relacionados. O sistema proposto, com a descrição dos elementos necessários para o funcionamento do mesmo, assim como as técnicas relacionadas, são apresentados no Capítulo 4. No Capítulo 5 são relatados os resultados obtidos durante a realização dos estudos de caso. Por fim, conclusões e trabalhos futuros são apresentados no Capítulo 6.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo é apresentada uma revisão da fundamentação teórica dos assuntos explorados nesta dissertação. Assim, na Seção 2.1 é apresentado um resumo sobre o tema RSSF. Em seguida, por se tratar de uma rede de sensores para detecção de movimentos, é apresentada uma introdução sobre sensores inerciais, discutida na Seção 2.2. Por fim, são discutidos conceitos de aprendizagem de máquina na Seção 2.3.

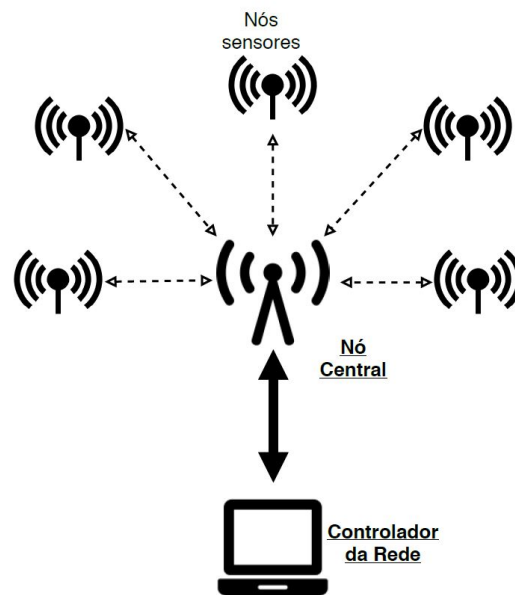
2.1 Redes de Sensores sem Fio

As RSSF, consistem em um termo para especificar um conjunto de pequenos dispositivos microcontrolados, cujo objetivo é realizar a medição de variáveis físicas no ambiente, como temperatura, vibrações, umidade, deslocamento, entre outras (LI *et al.*, 2019). As RSSF caracterizam-se por uma rede de comunicação com vários nodos que comunicam entre si. Normalmente, há um concentrador destes dados, algum elemento que conecte esta RSSF com o mundo exterior, ou seja outra rede, como a Internet. Essa caracterização das RSSF pode ser vista da Figura 1 (LOUREIRO *et al.*, 2003; FORSTER, 2016).

Na RSSF, cada nó corresponde a um dispositivo, que contém uma quantidade de sensores para monitoramento daquele ponto da rede, conforme a aplicação desejada. Assim, as RSSF caracterizam-se como sistemas flexíveis, distribuídos e dinâmicos, que possuem uma vasta gama de aplicações, como por exemplo, utilizadas para monitoramento de tráfego, de estruturas de pontes e túneis, controle de eficiência energética, em *Smarts Grids*, e ainda, no monitoramento do ambiente agrícola, seja monitorando plantações ou monitorando a pecuária, conforme pode ser observado na Figura 2 (FORSTER, 2016; FENG *et al.*, 2019).

Na maioria das aplicações, as RSSF trabalham com sensores colocados em pontos

Figura 1 – Exemplo de RSSF.



Fonte: Autor.

Figura 2 – Exemplo de RSSF: utilização em monitoramento animal.



Fonte: FORSTER (2016)

remotos, dificultando a manutenção. Desta forma, com a necessidade de reduzir as interferências humana nos sensores, uma maior autonomia energética é necessária. Essa autonomia baseia-se em hardware adequado (rádio, processador e sensores) que atenda essa necessidade com uma elevada eficiência. Uma fonte de energia, normalmente baterias, que possua uma boa relação entre tamanho e autonomia, minimiza a interferência humana, evitando substituições frequentes destas baterias (LOUREIRO *et al.*, 2003; FORSTER, 2016).

2.2 Sensores

Para desenvolvimento deste trabalho, são utilizados sensores do tipo MEMS, acelerômetro, giroscópios e magnetômetro, além de sensores de temperatura. Os sensores inerciais, acelerômetro e giroscópio tem o intuito de mensuração os movimentos dos eventos reprodutivos, tanto movimento de aceleração dos dispositivos como de rotação. Já o magnetômetro será utilizado como um dispositivo de sentido, de “pose” dos dispositivos e, por consequência, dos animais. Ainda, o sensor de temperatura será utilizado para mensurar as características fisiológicas dos animais, podendo ser um balizador para observação da saúde destes e, até mesmo, para avaliação do ciclo estral das fêmeas.

2.2.1 Micro Electro Mechanical System (MEMS)

Dentre as diversas tecnologias para fabricação de sensores, os *Micro Electro Mechanical System* (MEMS), são micro sistemas eletromecânicos que possuem a função de captar fenômenos mecânicos, térmicos, químicos, ópticos e/ou magnéticos, e transformá-los em sinais elétricos, para que possam ser melhor manipulados (BEEBY *et al.*, 2004; SHAEFFER, 2013).

Acelerômetro


Um acelerômetro é um dispositivo que consiste de uma massa de prova suspensa, utilizado para mensurar a aceleração própria de um sistema. O princípio básico consiste em uma massa de prova conectada a uma referência através de uma mola. Por estar fixado ao sistema a ser medido, o acelerômetro sofrerá as ações das mesmas forças impostas a este sistema. Dessa forma, é capaz de, a partir da detecção da variação de velocidade linear que é exercida sobre ele, determinar a aceleração em unidades g, onde 1g equivale a $9,8 \text{ m/s}^2$.

Os acelerômetros podem ser uniaxiais, geralmente sensíveis aos movimentos realizados no plano vertical; biaxiais, com capacidade de detectar o movimento nos planos vertical e ântero-posterior; e triaxiais, que mensura a aceleração nos planos vertical, ântero-posterior e médio-lateral (BEEBY *et al.*, 2004; ANDREJAŠIČ, 2008).

Existe uma vasta gama de acelerômetros, cada um com sua característica própria. Dentre os acelerômetros MEMS, os mais comuns são os capacitivos, piezoelétricos e os piezoresistivos. Contudo, ambos possuem a mesma ideia, onde são constituídos basi-

camente por um sistema massa, mola e amortecedor, entretanto em uma escala muito reduzida, essa ideia pode ser observada na Figura 3, ilustra o sistema massa-mola de um acelerômetro MEMS do tipo capacitivo (ANDREJAŠIČ, 2008; ACAR; SHKEL, 2008).

Figura 3 – Imagem microscópica de um acelerômetro.



Fonte: Adaptado de ACAR; SHKEL (2008)

Giroscópio

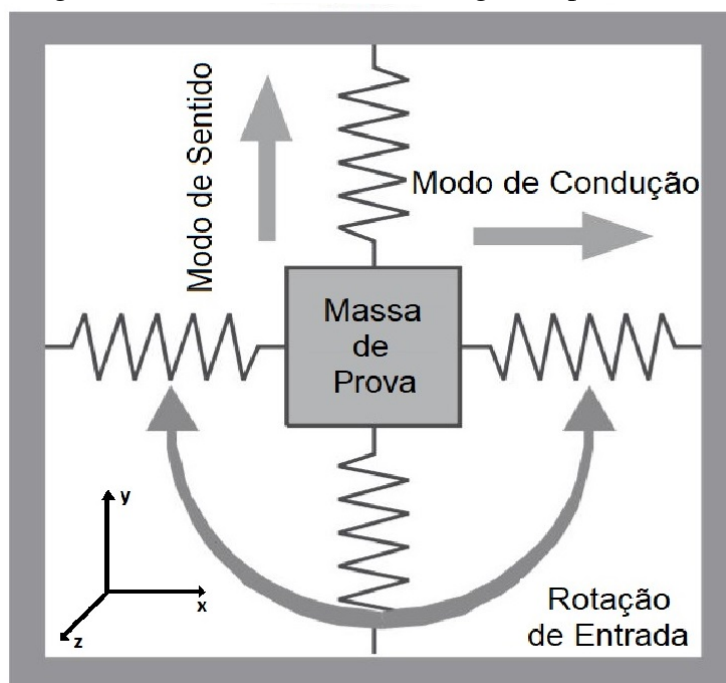
Os giroscópios consistem em mecanismos que são capazes de medir a orientação de um objeto, baseando-se no princípio da conservação do momento angular. Do ponto de vista estrutural, pode-se afirmar que esse mecanismo é semelhante a um acelerômetro, visto que também possui uma massa de prova suportada por molas de silício (ANDREJAŠIČ, 2008).

Os micro giroscópios possuem problemas relacionado a este conceito, visto que é quase impossível criar microelementos sem atrito. Assim, a maioria dos micro giroscópios MEMS, utilizam uma estrutura vibratória que une as energias oscilatórias para que seja possível mensurar a velocidade angular desejada.

Conforme mostrado na Figura 4, a massa de prova é excitada para que ocorra uma oscilação constante no eixo X. A rotação do eixo Z insere uma energia de oscilação no eixo Y cuja amplitude é proporcional à velocidade de rotação. Semelhante aos acelerôme-

tros, é possível incorporar o modo de detecção em uma malha de realimentação de força. Qualquer movimento ao longo do eixo dos sentidos é medido e uma força é aplicada para contrabalançar esse movimento. A magnitude da força necessária é então uma medida da taxa angular (BEEBY *et al.*, 2004).

Figura 4 – Estrutura interna de um giroscópio MEMS.




Fonte: Adaptado de BEEBY *et al.* (2004)

Magnetômetro

O magnetômetro MEMS mensura as forças dos campos magnéticos (B) ao seu redor. Com grande aplicabilidade, os magnetômetros estão muito difundidos e presentes em celulares e *tablets*, sendo utilizados para orientação tridimensional dos equipamentos em relação ao usuário. Ainda, pode ser utilizado para mensurar distúrbios magnéticos, o magnetômetro pode ser utilizado para medir o campo magnético local. Disposto nos três eixos X, Y e Z, os magnetômetros medem a intensidade do polo magnético em referência a cada eixo, o que pode ser representado na Figura 5. Posicionado de maneira correta, as intensidades em cada eixo podem ser usadas para orientação indicando para o norte magnético local (PRIMDAHL, 1979).

Figura 5 – Estrutura de um magnetômetro.



Fonte: PRIMDAHL (1979).

2.2.2 Sensor de Temperatura

Sensores de temperatura são dispositivos que convertem a energia térmica em sinais elétricos para uso em registro, monitoramento ou sinalização de mudanças de temperatura. São utilizados em automóveis, dispositivos médicos, computadores, celulares e diversos outros tipos de máquinas. Sensores de temperatura podem captar a temperatura a partir de uma característica física correspondente do dispositivo, como uma resistência elétrica, o campo eletromagnético ou radiação térmica sendo que a maneira como um sensor de temperatura funciona depende da propriedade física que constitui o mesmo (BEEBY *et al.*, 2004; SHIN *et al.*, 2020).

2.3 Aprendizagem de Máquina

A partir dos dados dos sensores, os elementos são uma série temporal. Assim, para detecção de evento optou-se pela utilização de aprendizagem de máquina, mais especificamente, aprendizagem supervisionada, assim alguns conceitos são importantes para compreensão deste trabalho.

Aprendizagem de máquina é um conceito que trata do desenvolvimento de modelos a partir da análise de dados, com o objetivo de produzir inteligência artificial. A ideia principal é que a máquina seja capaz de estimular ou "ensinar" seu próprio modelo para resolver uma tarefa particular, atingir um objetivo ou, de maneira mais formal, implementar uma função desconhecida (GOODFELLOW; BENGIO; COURVILLE, 2016). Para que isso seja possível, é necessário fornecer à máquina um conjunto de dados do problema em questão e uma função custo, para que ela consiga ajustar seu modelo interno a fim de

minimizar esse custo. Parafraseando MITCHELL (1997), um programa de computador "aprende" com a experiência e com a relação entre os níveis de tarefa, considerando que o desempenho nas tarefas melhora a experiência desse.

Nas subseções a seguir, são descritos os principais conceitos associados ao assunto, utilizados neste trabalho.

2.3.1 *Dataset* Rotulado

Em problemas de aprendizagem de máquina, é comum encontrar conjuntos de dados (*datasets*) rotulados, ou seja, que possuem tanto os valores esperados na entrada do modelo quanto as saídas esperadas para cada entrada. Tipicamente, atribui uma entrada descrita por vetor x a uma categoria identificada por um código (variáveis categóricas) ou por um número (variáveis quantitativas). Essas anotações (rótulos) são necessárias, para identificação dos eventos que ocorrem nas séries.

Esses conjuntos de dados anotados podem ser chamados de *dataset* rotulados. Este *dataset* pode ser rotulado utilizando uma distribuição de probabilidades sobre as classes, por exemplo. Esse tipo de classificação é comumente utilizado em modelos de reconhecimento de objetos, que também, a partir de sua evolução, acabam gerando os modelos de reconhecimento facial que observamos em softwares de análise de fotos e vídeos.

Contudo para classificação de um *dataset* é necessário que os modelos reconheçam um padrão existente nos dados. Esse reconhecimento de padrão é feito em elementos conhecidos, a partir da observabilidade do evento ou das características do mesmo (LISKA, 2012; GOODFELLOW; BENGIO; COURVILLE, 2016).

2.3.2 Classificação Binária

Dentro dos métodos de classificação de um conjunto de dados, tem-se o caso da classificação binária, quando diante dos dados de entrada há apenas duas possibilidades de eventos (GOODFELLOW; BENGIO; COURVILLE, 2016; RIBEIRO JUNIOR, 2016).

Muitos casos caracterizam esse tipo de decisão, principalmente casos de evento únicos, como um determinado dispositivo caiu ou não caiu no chão, um e-mail recebido é *spam* ou não é *spam*. Para o presente trabalho, deseja-se saber se houve ou não houve cópula entre os animais.

2.3.3 Aprendizagem Supervisionada

O supervisionamento é realizado a partir de um conjunto de dados rotulados previamente, com a finalidade de corrigir os erros do modelo ao longo da adaptação do mesmo. Ainda, aprendizagem supervisionada trata da tentativa de previsão de uma variável dependente, utilizando variáveis independentes.

A Tabela 1 mostra alguns exemplos de problema de previsão que podem ser tratados a partir de aprendizagem supervisionada. A ideia principal é que a variável dependente possui correlação com as variáveis independentes e pode ser prevista a partir do conhecimento delas. Essa previsão pode acontecer a partir de modelos lineares (*e.g.*, regressão linear) ou não-lineares.

Tabela 1 – Variáveis Independentes vs Variável Dependente.

Variáveis Independentes	Variável Dependente
Anos de carreira; Formação; Idade	Salário
Idade do carro; Idade do motorista	Risco de acidente automotivo
Temperatura	Receita de venda de sorvetes
Histórico escolar	Nota no ENEM

Fonte: Adaptado de HONDA; FACURE; YAOHAO (2017).

Vale ressaltar que a característica principal de um sistemas de aprendizagem supervisionada é que os dados utilizados para treinamento devem possuir as respostas desejadas. Ou seja, é necessário que as variáveis dependentes apareçam entre os resultados rotulados, resultante das variáveis independentes observadas (GOODFELLOW; BENGIO; COURVILLE, 2016; HONDA; FACURE; YAOHAO, 2017).

Existem várias técnicas de solução de problemas de aprendizagem supervisionada. Este trabalho fará uso de quatro técnicas já difundidas nos referenciais da área: regressão logística, classificação bayesiana gaussiana, árvores de decisão e classificador vetores de suporte. Esta revisão é importante em virtude de serem estas as técnicas utilizadas e comparadas entre si para a detecção do evento de reprodução, foco deste trabalho.

Regressão Logística

Regressão logística é uma técnica recomendada para situações onde a variável dependente é de natureza binária, podendo ser as variáveis independentes categóricas ou não. A regressão logística permite estimar um grau de confiança (semelhante à uma probabilidade) associado com a ocorrência de um evento levando em conta um conjunto de variáveis independentes entre si, como mencionado na subseção sobre aprendizagem supervisionada.

No caso da variável dependente Y assumir apenas dois possíveis estados, considerando uma classificação binária, e haver um conjunto de k de variáveis independentes, sendo X_1, X_2, \dots, X_k as variáveis, o modelo de regressão logística pode ser escrito conforme equação (1), também conhecida como função sigmóide.

$$P(Y = 1) = \frac{1}{1 + e^{-g(x)}} \quad (1)$$


Onde $g(x) = B_0 + B_1X_1 + \dots + B_kX_k$, os coeficientes B_0, B_1, \dots, B_k são identificados diante do conjunto de dados, baseando-se no método da máxima verossimilhança, onde busca-se encontrar o conjunto de combinações de coeficientes que minimiza o erro total de previsão dos dados utilizados para o ajuste do modelo.

A equação (2) caracteriza $G(x)$, de tal forma que a Figura 6 é a representação da equação (1), descrevendo o comportamento probabilístico no formato da letra S, que é a característica da regressão logística (KLEINBAUM *et al.*, 2002; LISKA, 2012).

$$g(x) \rightarrow \begin{cases} +\infty, \text{ então } P(Y = 1) \rightarrow 1 \\ -\infty, \text{ então } P(Y = 1) \rightarrow 0 \end{cases} \quad (2)$$

Conforme observado no gráfico da função sigmóide, a regressão logística mapeia uma regressão linear das variáveis independentes para uma faixa de valores entre 0 e 1, a fim de representar o grau de confiança na classificação do evento binário. Assim, como já mencionado, a utilização de regressão logística torna-se mais adequada para eventos de classificação binária, onde o evento ocorre ou não ocorre. Contudo, cabe ressaltar que há uma faixa de indecisão, visto que a característica da regressão logística é uma curva S. Essa indecisão pode ser minimizada conforme a correlação entre a variável independente e a variável dependente, e também com um ajuste de limiar de decisão (*threshold*) (KLEINBAUM *et al.*, 2002; GOODFELLOW; BENGIO; COURVILLE, 2016).

Figura 6 – Função Sigmóide - Curva característica da Regressão Logística.



Fonte: Adaptado de KLEINBAUM *et al.* (2002).

Classificação Bayesiana Gaussiana

A abordagem bayesiana estabelece relações de um evento, utilizando as probabilidades a priori e a densidade de probabilidade do mesmo. Para tal, uma classe de eventos possui variáveis correlacionadas à geração deste evento, onde a classe é indicada por ω_i , onde ω indica o evento e i o mecanismo indicador deste evento ($i = 1, 2, \dots, k$). Um conjunto de variáveis independentes, X , que estão relacionadas ao evento $X = (x_1, x_2, \dots, x_k)$. De tal forma, a abordagem bayesiana supõe que as probabilidades de um determinado evento $P(\omega_i)$, assim como a densidade de probabilidade conjunta da combinação deste referido evento com cada classe existente $p(X|\omega_i)$ são conhecidas.

Considerando que não se tenha conhecimento das probabilidades de ocorrência de um acontecimento, é possível classificar um evento qualquer X , como sendo a classe de maior probabilidade. Contudo, essa a abordagem pode estar equivocada, visto que mesmo obtendo êxito ao estimar $P(\omega_i)$, as probabilidades de não ocorrer seriam descaracterizadas. Desta forma, para as probabilidades, o teorema de Bayes mostra-se satisfatório, conforme equação (3) (PINTO, 2015):

$$P(\omega_i|X) = \frac{P(\omega_i)P(X|\omega_i)}{P(X)} \quad (3)$$

A equação (3), sendo $P(\omega_i|X)$ o objetivo desta, trata-se da probabilidade *a posteriori*, ou seja, a probabilidade da tomada de decisão. $P(\omega_i)$ é considerado a probabilidade *a priori* do evento, $P(X|\omega_i)$ é a verossimilhança do evento e $P(X) = \sum_{j=1}^k P(\omega_j)P(X|\omega_j)$,

onde k é o número máximo de eventos associados.

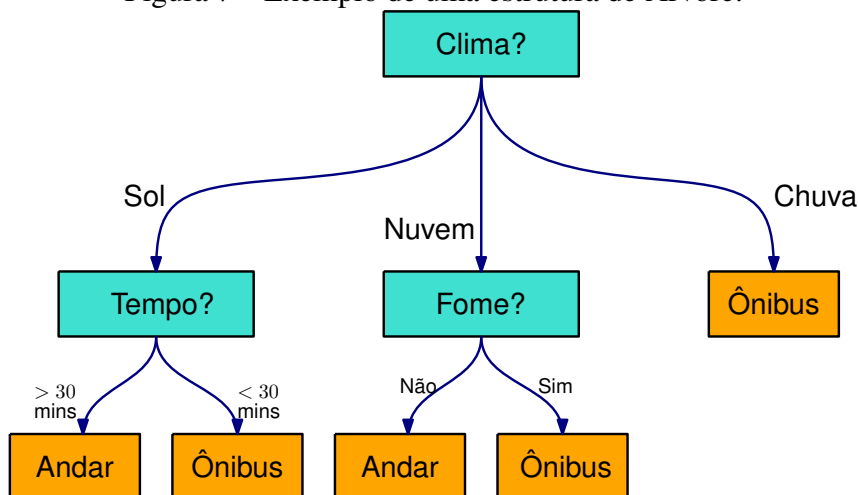
Contudo, a intenção do classificador bayesiano gaussiano é unir a utilização de probabilidades conforme estrutura de Bayes, mencionado anteriormente, com a distribuição gaussiana. Assim, a situação condicional da densidade de probabilidade $p(X|\omega_i)$ trata-se de uma distribuição gaussiana. Este classificador recebe muita relevância devido a possibilidade desta distribuição poder ser tratada analiticamente. Isso ocorre devido a maioria das vezes os dados observados poderem ser considerados perturbações aleatórias de um protótipo μ , além das estatísticas amostrais possuírem uma distribuição muito próxima a uma distribuição gaussiana, devido ao teorema do limite central.

Árvores de decisão

Árvores de decisão são métodos não-paramétricos de aprendizado supervisionado muito utilizados em tarefas de classificação.

Árvores, na área de computação, referem-se a estruturas de dados compostas por um conjunto de elementos que armazenam informações em cada ponto, chamados de nós. Na Figura 7, os nós são representados pelos retângulos com as perguntas, a partir dos quais obtêm-se a divisão dos eventos, conforme a resposta que ocorre. Além disso, toda árvore possui um nó chamado raiz, que possui o maior nível hierárquico (o ponto de partida) e ligações para outros elementos, denominados filhos. Esses filhos podem possuir seus próprios filhos que por sua vez também possuem os seus. O nó que não possui filho é conhecido como nó folha ou terminal.

Figura 7 – Exemplo de uma estrutura de Árvore.



Fonte: Adaptado de GOODFELLOW; BENGIO; COURVILLE (2016).

A árvore de decisões emprega o conceito de árvore da computação, onde cada decisão é tomada em um nó, criando um caminho de decisões a partir do nó central até cada folha. Assim, analogamente, as folhas representam os rótulos das classes e os ramos o conjunto de valores que levam até essa folha. Com isso, o método realiza a decisão em cada nó, baseando-se na estatística dos ramos ligados àquele nó, chegando até a folha com o rotulamento.

As árvores de decisão estão entre os modelos de aprendizado mais populares devido à sua inteligibilidade e simplicidade, permitindo que seja possível avaliação dos ramos estabelecidos para as decisões, tornando viável não apenas a aprendizagem, mas a compreensão desta.

Classificador por Vetores de Suporte

Support vector classifier (SVC), é um classificador de dados baseado na utilização de máquinas de vetores de suporte. Essas máquinas, são modelos de aprendizagem supervisionada associados que analisam dados para classificação e análise de regressão.

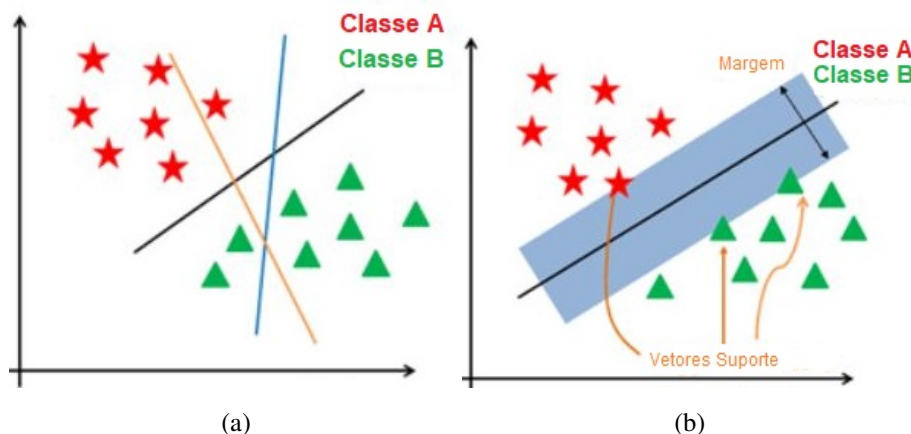
Dado um conjunto de exemplos de treinamento, cada um marcado como pertencente a uma de duas categorias, um modelo de treinamento por máquinas de vetores de suporte constrói um modelo que atribui novos exemplos a uma categoria ou outra, tornando-o um classificador linear binário não probabilístico. Isso faz com que sejam mapeado exemplos de treinamento para pontos no espaço de modo a maximizar a largura da lacuna entre as duas categorias. Novos exemplos são mapeados nesse mesmo espaço e considerados pertencentes a uma categoria com base em qual lado da lacuna eles se enquadram. Além de realizar a classificação linear, as máquinas de vetores de suporte podem realizar com eficiência uma classificação não linear, mapeando implicitamente suas entradas em espaços de recursos de alta dimensão (NAVLANI, 2018).

O SVC oferece, na média uma uma precisão mais alta em comparação com outros classificadores, como regressão logística e árvores de decisão. O SVC é conhecido por seu truque de *kernel* para lidar com espaços de entrada não lineares. Ele é usado em uma variedade de aplicativos, como imageamento para detecção de rostos, detecção de intrusão, classificação de e-mails, artigos de notícias e páginas da Web, classificação de genes e reconhecimento de escrita.

O principal objetivo é segregar o conjunto de dados fornecido da melhor maneira pos-

sível. A distância entre os pontos mais próximos é conhecida como margem. O objetivo é selecionar um hiperplano com a máxima margem possível entre os vetores de suporte no conjunto de dados fornecido. O SVC procura o hiperplano marginal máximo, gerando hiperplanos que segregam as classes da melhor maneira e seleciona o hiperplano direito com a segregação máxima dos pontos de dados mais próximos, conforme mostrado na Figura 8, e assim promover a classificação dos dados (GOODFELLOW; BENGIO; COURVILLE, 2016; NAVLANI, 2018).

Figura 8 – Exemplo do funcionamento do SVC, (a) busca dos vetores, (b) ampliação da margem



Fonte: Adaptado de NAVLANI (2018).

2.3.4 Avaliação de Desempenho

Para avaliar o desempenho de sistemas de classificação, neste caso de aprendizagem supervisionada, algumas métricas são necessárias. Em problemas de classificação binária com dados desbalanceados (maior ocorrência de uma classe em relação à outra), é necessário ter atenção à qual métrica se torna mais relevante para a aplicação, visto que um modelo trivial poderia ter uma taxa de acerto com valor aparentemente alto baseando-se apenas em um palpite constante da classe majoritária ou um palpite aleatório baseado na estatística base das classes. Desta forma, um breve contexto das principais métricas de avaliação de desempenho torna-se necessário.

Precisão

Precisão avalia o quão exato é o método. Para tal, ela avalia a quantidade de resultados corretos em todo universo resultados previstos como pertencentes à classe 1 (positivos). A precisão (P) pode ser definida baseada na equação (4), onde esta é a razão entre a quantidade de resultados positivos verdadeiros (T_p) e a soma de resultados verdadeiros e resultados positivos falsos (F_p) (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$P = \frac{T_p}{T_p + F_p}. \quad (4)$$

Sensibilidade (*Recall*)

Sensibilidade, do inglês *recall*, trata-se do número de exemplos classificados como pertencentes a uma classe, que realmente são daquela classe. A sensibilidade (R) pode ser calculada baseada na equação (5), onde é obtida a razão entre a quantidade de resultados positivos verdadeiros (T_p) e a quantidade de positivos verdadeiros mais a quantidade de falsos negativos (F_n) (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$R = \frac{T_p}{T_p + F_n} \quad (5)$$

Precision-Recall

A curva de união entre precisão e *recall* pode trazer várias informações sobre o classificador. Uma área maior sob a curva representa tanto o alto *recall* quanto a alta precisão, onde a alta precisão está relacionada a uma taxa baixa de falsos positivos e o alto *recall* está relacionado a uma baixa taxa de falsos negativos. Essas altas pontuações de ambos os índices, mostram que o classificador está retornando resultados precisos (alta precisão), bem como retornando a maioria de todos os resultados positivos (alto *recall*).

Um sistema com alto *recall* e baixa precisão retorna muitos positivos (classe 1), mas a maioria de seus rótulos previstos são alarmes falsos. Ainda, um sistema com alta precisão, mas baixa sensibilidade é exatamente o oposto, com poucos alarmes falsos mas sendo incapaz de detectar os eventos positivos (os quais são erroneamente classificados como negativos). Sendo assim, o ideal é que a aprendizagem supervisionada busque um sistema dito ideal, onde há alta precisão e alto *recall*, retornando resultados rotulados corretamente (GOODFELLOW; BENGIO; COURVILLE, 2016).

Acurácia

Acurácia é uma métrica de taxa de acerto. Em problemas com classes desproporcionais, ela causa uma falsa impressão de bom desempenho, devido ao modo de cálculo desta métrica. Um bom exemplo desse caso, em um *dataset* em que 80% dos rótulos pertencem a uma classe, é possível obter uma acurácia dessa ordem também, em torno de 80%, apenas retornando a saída como sendo a da classe majoritária. Contudo, embora tenha acurácia de 80%, o sistema seria incapaz de detectar os eventos da classe minoritária. Mesmo assim, é importante a avaliação, para mensurar esse dados e comparar com as outras métricas de avaliação de desempenho.

A acurácia A , pode ser calculada conforme a equação (6), onde o número de acertos é dividido pelo número total de exemplos. Ou seja, o total de acertos positivos (T_p) mais o total de acertos negativos (T_n), dividido pela soma total dos exemplos, acertos positivos (T_p), acertos negativos (T_n), erros positivos (F_p) e erros negativos (F_n) (GOODFELLOW; BENGIO; COURVILLE, 2016).

$$A = \frac{T_p + T_n}{T_p + T_n + F_p + F_n} \quad (6)$$

F1 Score

F1 Score é uma maneira de visualizar as métricas de precisão e sensibilidade juntas. A união das duas métricas poderia ser realizada através da média aritmética, contudo isso pode ser um problema quando tem-se valores baixos de algum dos índices.

O *F1 Score* ($F1$) é calculado através de uma média harmônica. Esse cálculo é demonstrado pela equação (7), o inverso da média aritmética dos inversos dos termos P e R .

$$F1 = \frac{2 * P * R}{P + R} \quad (7)$$

Como o *F1 score* é resultante da média harmônica entre P e R , seu resultado será dominado pela métrica de pior desempenho entre as duas (GOODFELLOW; BENGIO; COURVILLE, 2016).

3 ANÁLISE DO ESTADO DA ARTE

Neste capítulo é apresentada a análise do estado da arte no tema, onde são expostos os principais trabalhos relacionados com esta dissertação. Na seção 3.1, são mostrados trabalhos relacionados com detecção de movimento e a utilização dos MEMS para esta finalidade. Na seção 3.2 são apresentados estudos relacionados com o monitoramento animal e como a detecção de movimento migrou para esta utilização. E por fim, na seção 3.3, apresenta-se um resumo dos trabalhos, através de uma comparação destes com esta dissertação.

3.1 Detecção de Movimento em Seres Humanos

O uso de sistemas para monitoramento de movimento em seres humanos é de interesse para o desenvolvimento deste trabalho, uma vez que diversas abordagens são realizadas, e que podem ser transpostas para outras áreas. Foram desenvolvidos aparatos para detecção de quedas, monitoramento de desempenho em atividades desportivas ou ainda, para realizar detecção de patologias. O entendimento dos trabalhos estudados é importante, pois várias das propostas empregam sistemas que podem ser usados no monitoramento de animais

Tratando-se de detecção de movimentos, BOISSY *et al.* (2007) desenvolveu um estudo para analisar a utilização de bengalas para melhorar as funções motoras, em pessoas que tiveram esta capacidade reduzida, principalmente, por Acidente Vascular Cerebral (AVC). Para realizar este estudo, foi utilizado um conjunto de sensores, formados por acelerômetros de três eixos e giroscópio de eixo único, fixados em ambos tornozelos da pessoa e no punho. Ainda, na bengala proposta, foi adicionada uma célula de carga, para inferir a pressão exercida sobre o objeto, e dois acelerômetros para analisar a movimenta-

ção do objeto. Este estudo, mostrou-se satisfatório para auxiliar na orientação dos indivíduos, com intuito de melhorar o progresso destes em suas condições de movimentos. Os sensores criaram um conjunto que pode avaliar desde a pressão sobre a bengala, que caso esteja muito elevada não contribui para evolução motora. Cria-se, portanto, um cenário de avaliação dos movimentos completos, podendo estabelecer os sentidos dos movimentos que o indivíduo realiza, e compreender a sua evolução.

A partir de sensores de aceleração e de velocidade angular, TORRES (2018), implementou um sensor vestível com o intuito de detecção de quedas de idosos. O sensor vestível possui um módulo com acelerômetro e giroscópio para identificação dos movimentos bruscos, ou seja, possíveis quedas. Ainda, o trabalho implementa o sensor proposto em um possível sistema *home health*, onde, mediante a detecção de queda do idoso, podem ser acionados serviços de emergência para prover o atendimento. Para o sensor vestível, o trabalho citado utilizou duas métricas de avaliação do desempenho, sensibilidade e especificidade, onde sensibilidade é a capacidade do sensor de detectar quedas, avaliando o desempenho quanto aos falsos negativos, e especificidade, é a capacidade de detectar apenas a queda, avaliando o desempenho em relação aos falsos positivos. Assim, o trabalho mostrou um desempenho de 96% e 100%, para sensibilidade e especificidade, respectivamente.

Ainda tratando-se de detecção de movimento e sensores vestíveis, no trabalho de JOSEPH *et al.* (2019), os autores propõem um sistema para aquisição de dados, detecção de quedas, monitoramento e alertas. Para tal, o sistema utiliza um sensor de temperatura, sensor de fluxo sanguíneo e um acelerômetro de três eixos. Este sensor é utilizado para realizar o monitoramento principalmente de idosos e pessoas com doenças que necessitam ficar sozinhas. A técnica consiste em um sistema de alarme que envia mensagens para celulares cadastrados, a partir de uma queda, uma elevação anormal de temperatura ou, ainda, uma oscilação da frequência cardíaca.

Outro trabalho, proposto por DATTA *et al.* (2020) tem o intuito de monitorar pacientes que sofreram em decorrência de AVC. Segundo os autores essa doença causa, em vários casos, a paralisia em metade do corpo, denominada de hemiparesia. Desta forma, o monitoramento contínuo do paciente após o acidente pode auxiliar médicos na recuperação dos mesmos. Para tanto, o sistema proposto utiliza dois acelerômetros solidários ao paciente através de uma pulseira em cada um dos membros superiores. A proposta do sis-

tema é mensurar a frequência de oscilação dos membros, sendo essas boas medidas para acompanhar o nível de atividade física do paciente. O estudo foi realizado em 32 pacientes com AVC agudo com níveis variados de hemiparesia, e os resultados indicaram que a abordagem proposta pode distinguir hemiparesia moderada e grave, com uma precisão média de 91%.

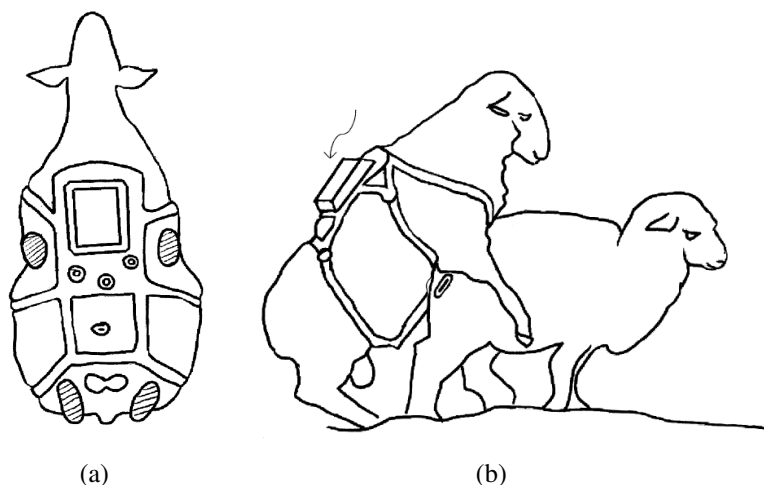
3.2 Sistemas para Monitoramento Animal

Em WOUTERS *et al.* (1994), os autores propõem um pequeno e leve dispositivo para utilização no monitoramento de criações de grandes quantidade de animais. O chip, utiliza sensores de temperatura e aceleração para verificação das condições dos animais. A proposta apresentada contempla um chip multi-sensor, de baixo consumo energético, que é injetado na pele no animal, capaz de armazenar os dados coletados dos sensores. Quando houver a necessidade de verificação destes dados, basta a aproximação de uma antena para comunicação em modulação em amplitude para captar e decodificar os dados, de maneira que estes podem ser lidos em um computador.

Na patente de BOCQUIER (2005), o autor descreve um sistema para detecção da cópula de ovinos. O sistema proposto utiliza um conjunto de sensores vestíveis nos machos que contam com sistemas de comunicação RFID, conforme mostrado na Figura 9a. O sistema propõe a utilização de *tags* RFID passivas nas fêmeas: quando o macho realiza o acasalamento com a fêmea o sistema ativo presente nele aciona o sistema passivo da fêmea, possibilitando realizar a leitura do código da fêmea e, assim, registrar o acasalamento ou as tentativas deste no colete do macho. Quando há necessidade de aquisição destes dados, é necessário retirar o colete do macho para assim ler os dados, conforme a Figura 9b demonstra.

O trabalho apresentado por SMITH *et al.* (2006) apresenta uma proposta de sistema de monitoramento de bovinos. O sistema proposto pelo autores trata de um conjunto de sensores para temperatura, frequência cardíaca, posicionamento e movimentação dos animais. A partir de um microcontrolador, os dados são adquiridos e ficam disponíveis para envio para uma central através de uma comunicação sem fio ZigBee. Para que seja possível, foi implementado um sistema de armazenamento de dados no microcontrolador, para que, quando o animal estiver ao alcance da rede de comunicação, os dados sejam descarregados. Os dados brutos mas, a partir de um aplicativo, estes ficam disponíveis

Figura 9 – Sistema para detecção da cópula de ovinos, através de sensores vestíveis nos machos (a), que se comunicam com sensores RFID passivos no dorso das fêmeas (b).




Fonte: Adaptado de BOCQUIER (2005).

para observação direta na forma gráfica, podendo ser utilizados para a análise do comportamento dos indivíduos conforme o decorrer do dia. Os autores afirmam que o sistema demonstra potencial para melhorar o bem estar animal.

O modelo patenteado por LISBOA; GAMOU; ZUBELZU (2017), trata de um sistema para detecção de montas, desenvolvido principalmente para bovinos. Utilizando sensores com codificação RFID na cauda da fêmea e no lombo dos touros, conforme as indicações em preto na Figura 10, o sistema envia os dados dos sensores via rádio para um concentrador de dados. Este concentrador, também realiza a análise dos sinais, fazendo com que seja possível a identificação de monta e de quais animais estavam envolvidos.

Figura 10 – Sistema para detecção da cópula, sensores na cauda da fêmea e no dorso no macho.



Fonte: Adaptado de LISBOA; GAMOU; ZUBELZU (2017).

No trabalho de BUSCH; STÏPMANN; EWALD (2017), os autores buscam avaliar o comportamento animal a partir de colares colocados no pescoço de cada um, onde cada

colar possui um microcontrolador de baixa potência, um acelerômetro de três eixos, dois microfones (para captar o som do ar e do corpo) e um transmissor de Rádio Frequência (RF). Voltado para vacas leiteiras, o trabalho tenta distinguir as atividades de pose dos animais. Utilizando o sensor de aceleração configurado com uma sensibilidade de $\pm 2g$ e uma taxa de amostragem de 25 amostras/segundos, os autores realizam uma série de medições em um pequeno grupo de vacas leiteiras isoladas em um estábulo. Para contrapor a aquisição de dados, os autores utilizaram vídeo para monitoramento destes animais. Utilizando uma etapa de classificação de eventos binária, ou seja, o evento ocorreu ou não, e propondo a utilização de recursos computacionais simples, os autores realizam a detecção picos dos eventos, e a contagem da duração dos eventos. Desta forma, o sistema proposto alcançou uma precisão de até 90% e uma redução de 2,6% do tamanho dos dados brutos adquiridos.

O trabalho BUSCH; STÏPMANN; EWALD (2018), proposto pelo mesmo grupo anterior, busca a otimização do algoritmo existente, avaliando três parâmetros: a taxa de amostragem, a quantidade de amostras do sensor e a redução de dados, a partir de outro sensor. O trabalho propõe uma análise da identificação dos dados conforme os parâmetros citados. Contudo, o algoritmo proposto leva em conta não apenas a utilização de variáveis de tempo, como valor médio e variância, mas também variáveis de frequência, utilizando uma transformada rápida de Fourier (*Fast Fourier Transform* - FFT), propondo um algoritmo de localização de pico e um filtro passa-alta digital para reconhecer padrões repetitivos. Foram avaliados quarenta e oito combinações diferentes de parâmetros de taxa de amostragem, tamanho da janela e sobreposições de dados para encontrar uma seleção ideal de parâmetros. O trabalho mostra que é possível aceitar uma pequena perda de precisão, em troca de uma maior possibilidade de parâmetros. A melhor opção possível para um classificador com eficiência de recursos foi feita para uma taxa de amostragem de 10 Hz e um tamanho de janela de 64 amostras, alcançando uma precisão 87%.

No trabalho de CAMARGO (2019), o autor desenvolveu um sistema de monitoramento animal composto por um dispositivo com acelerômetros. O dispositivo utiliza um sistema IoT, baseado em comunicação *Bluetooth* de baixa potência. Os experimentos foram realizados em animais domésticos, como cães e gatos, e, também, em ovinos, carneiros e borregos. A proposta do autor é o monitoramento da rotina dos animais, avaliando comportamentos ditos normais, para identificar casos anormais, tais como doenças ou

tentativas de fugas dos animais. O autor estabeleceu dois testes com o sistema proposto. O primeiro, realizado com os animais domésticos, mostrou bons resultados. O monitoramento mostrou-se efetivo em adquirir e monitorar a rotina dos animais, conseguindo diferenciar os eventos ditos normais, mesmo em períodos mais ativos dos animais, com momentos anormais, de maior estresse do animal. Contudo, no teste realizado em ovinos, a proposta não apresentou o mesmo sucesso. O autor atribui isso ao fato deste tipo de animais encontrarem-se em ambientes maiores e, uma vez que o protocolo utilizado foi *Bluetooth* que em geral tem alcance de alguns metros, um número considerável de dados foi perdido tornando a análise dos mesmos inviável.

3.3 Resumo

Os trabalhos BOISSY *et al.* (2007), TORRES (2018), JOSEPH *et al.* (2019) e DATTA *et al.* (2020), apresentados na Seção 3.1, tratam de análise de dados e detecção de movimento em diversas áreas de atuação. Esses trabalhos servem como embasamento para o desenvolvimento do presente trabalho. Contudo, os trabalhos apresentados na Seção 3.2 apresentam uma relação mais direta com a proposta desta dissertação. Assim, com a finalidade de sintetizar, na Tabela 2 é possível observar um resumo dos trabalhos apresentados, comparando-os com a proposta desenvolvida neste trabalho. Cabe salientar, que mesmo diante de todo o esforço de pesquisa bibliográfica, não foram encontrados trabalhos como o proposto, principalmente por utilizar um dispositivo intravaginal na fêmea para verificação da reprodução animal.

Tabela 2 – Trabalhos relacionados (resumo).

Trabalho	Monitoramento Animal	Monitoramento Reprodutivo	Utilização RSSF	Processamento <i>Machine Learning</i>	Dispositivo Intravaginal
BOCQUIER (2005)	✓	✓			
SMITH <i>et al.</i> (2006)	✓		✓		
LISBOA; GAMOU; ZUBELZU (2017)	✓	✓			
BUSCH; STÍPMANN; EWALD (2017)	✓		✓	✓	
BUSCH; STÍPMANN; EWALD (2018)	✓		✓	✓	
CAMARGO (2019)	✓		✓		
Proposta	✓	✓	✓	✓	✓

4 SISTEMA PROPOSTO

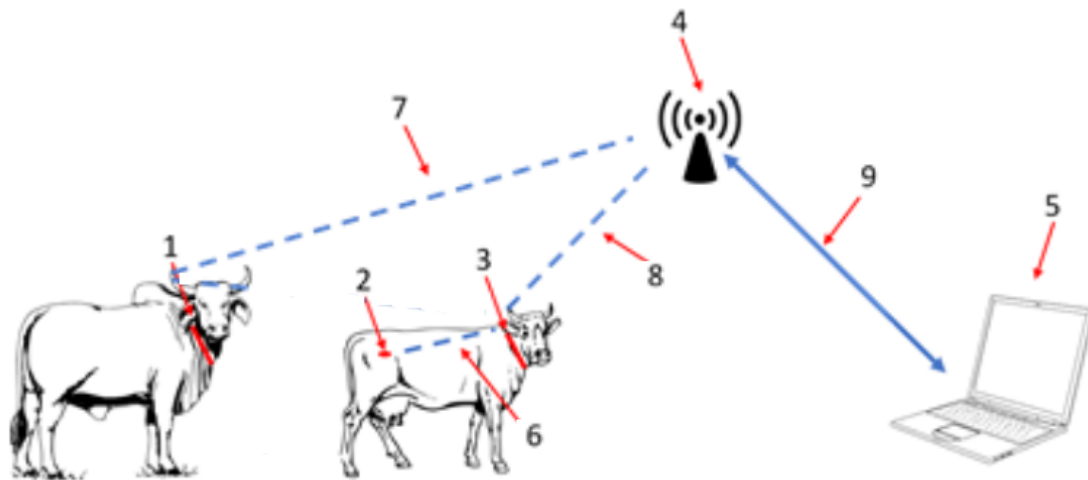
Neste capítulo é apresentado o escopo do projeto como um todo, detalhando o sistema em si e os materiais utilizados para a realização do mesmo. Na seção 4.1, o sistema é explicado de forma mais aprofundada. Na seção 4.2 são mostrados todos os passos necessários para desenvolvimento dos dispositivos de aquisição dos dados. A comunicação da RSSF é descrita na seção 4.3. A aquisição dos dados e todos os processos necessários para isso são descritos na seção 4.4. Por fim, na seção 4.5 são descritos os elementos necessários para que haja a identificação dos eventos de interesse no monitoramento animal.

4.1 Proposta

O sistema proposto é baseado em uma rede de sensores sem fio composta essencialmente por três dispositivos: colar do macho (1), dispositivo intravaginal (DIV) (2) e colar da fêmea (3), conforme descrito pela Figura 11. O posicionamento dos dispositivos são proposta do próprio grupo de veterinária que motivou esse trabalho, conforme mencionado na seção 1.1.

O sistema possui um concentrador de dados (4), utilizado para coletar os dados de todos os sensores. Anexo a este concentrador, há também um sistema computacional (5) para realizar a detecção dos eventos. Os dispositivos realizam comunicação através de enlaces de comunicação utilizando tecnologia LoRa (6-8). O sistema computacional e o concentrador de dados realizam a troca de informações a partir de um enlace físico *Universal Serial Bus* (USB) (9).

Figura 11 – Diagrama pictórico do sistema proposto.



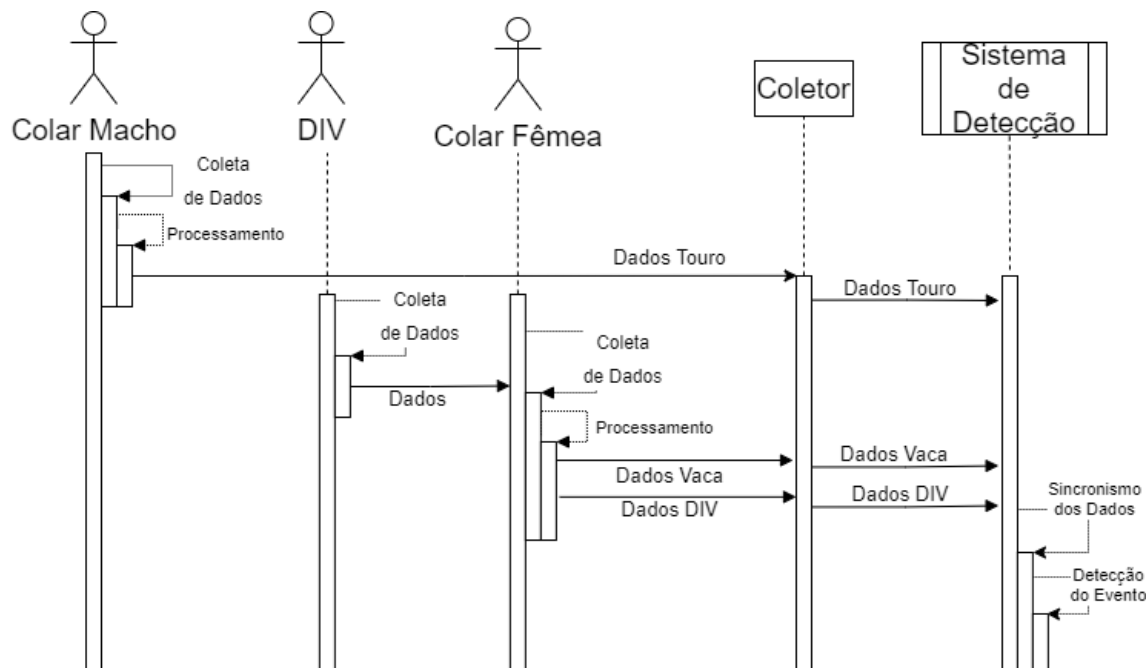
Fonte: MÜLLER; MENEGASSI (2018).

A RSSF montada utilizando o protocolo de comunicação LoRa, e é composta por múltiplos dispositivos. Contudo, existem apenas 3 categorias diferentes de dispositivos na rede, como usuários: macho, fêmea e DIV. A interação entre eles pode ser observada no diagrama de seqüências mostrado na Figura 12.

O dispositivo do macho é independente, ou seja, ele é responsável pela aquisição de informações do macho e envia diretamente para o coletor de dados.

No caso do dispositivo da fêmea, este possui uma conexão curta com o DIV. Isso ocorre devido à absorção dos sinais de RF através dos tecidos orgânicos, fazendo com que a comunicação com o DIV tenha alcance muito reduzido. Desta forma, é necessário a formação de uma rede de retransmissão entre o DIV e o dispositivo da fêmea para garantir o alcance do sinal. Assim, o colar da fêmea recebe os dados do DIV e os encaminha para o coletor.

Figura 12 – Diagrama de seqüência da comunicação.



Fonte: Autor.

4.2 Desenvolvimento do Dispositivo

Considerando que o sistema de monitoramento animal é feito com sensores vestíveis, é muito importante tornar estes dispositivos pequenos e leves. Conseqüentemente, isso afeta a escolha de componentes para implementação do hardware, levando à preferência pelos que possuem o grau de miniaturização necessário para a aplicação. Visando o desenvolvimento de hardware único, ou seja, o mesmo hardware para os três sensores, foi adotada a menor dimensão necessária, especificamente a do DIV. A proporção necessária pode ser observada na Figura 13, a partir de uma comparação com uma moeda de R\$1,00, além do dimensionamento mostrado na imagem.

Figura 13 – Invólucro utilizado para o dispositivo intravaginal.



Fonte: Autor.

4.2.1 Elementos de Hardware

Microcontrolador

Para realizar o processamento dos sinais do sistema, foi escolhido o microcontrolador ATmega328P. Este microcontrolador, opera com um clock de 20 MHz e é capaz de executar 20 Milhões de Instruções Por Segundo (MIPS). Com baixo consumo, o ATmega328P é baseado numa arquitetura *Reduced Instruction Set Computer* (RISC), possui 6 conversores analógico-digitais, possibilidade de comunicação *Universal Asynchronous Receiver/Transmitter* (UART), *Serial Peripheral Interface* (SPI), *Inter-Integrated Circuit* (I²C), 32KBytes de memória de programa, 1KBytes EEPROM e 2KBytes Internal SRAM (MICROCHIP, 2020).


Comunicação LoRa

Considerando a necessidade de comunicação à longa distância, além do uso de radiação restrita (bandas ISM), foi escolhida a faixa de operação de RF na faixa de 900 MHz. O protocolo de comunicação LoRa (LONg RANGE), desenvolvido pela empresa Cycleo e adquirida pela Semtech, consegue unir baixo consumo energético com grande alcance de comunicação (SEMTECH, 2020).

A camada física do protocolo LoRa faz uso de modulação baseada em variações da frequência da portadora *Chirp Spread Spectrum*, desenvolvida inicialmente para utilização em radares nos anos de 1940. Já as camadas de aplicação e de enlace são abertas e mantidas pelo comitê técnico da LoRa-Alliance, uma associação composta por mais de 500 empresas e sem fins lucrativos (ALLIANCE, 2016).

Para o referido trabalho, utilizou-se o transceptor LORA RFM95W (Figura 14), o qual utiliza o circuito integrado (CI) controlador SX1276 e um módulo com faixa de transmissão entre 868 e 915 MHz, com taxa de dados de até 37,5 kbps e sensibilidade de enlace entre -111 e -148 dBm, conforme a largura de banda utilizada (SEMTECH, 2020). A utilização deste tipo de dispositivo, pode ser um facilitador no futuro para aplicação de um sistema LoRaWan, que possibilita acesso a novas tecnologias com internet das coisas (IoT).

Figura 14 – Placa de desenvolvimento LoRa SX1276.




Fonte: Adaptado de HOPERF (2020).

Sensor MPU-9250

Fabricado pela TDK Invensense, o sensor MPU-9250 possui a possibilidade de sensoriamento a 9-eixos, visto que esse possui MEMS, acelerômetro, giroscópio e magnetômetro, todos de três eixos. Ainda, a placa de desenvolvimento do MPU-9250 possui um sensor de temperatura integrado. Em um encapsulamento *Quad Flat No leads* (QFN) de 3x3x1mm, o CI possui uma grande aplicação em *smartphones*, *tablets*, sensores vestíveis, entre outros equipamentos que necessitem destas funcionalidades.

Figura 15 – Placa de desenvolvimento MPU - 9052.



Fonte: Adaptado de INVENSENSE (2020).

A placa de desenvolvimento MPU-9250 é um pacote de sistemas que combina dois CI internamente: o CI MPU-6500, onde encontram-se contidos o acelerômetro, o giroscópio e uma unidade de processamentos, e o CI AK8963, contendo o magnetômetro digital.

Com baixo consumo de energia em repouso, de aproximadamente $6,4\mu\text{A}$ e uma resolução de 16 bits, o MPU-9250 permite configuração da sensibilidade do acelerômetro entre $\pm 2\text{g}$, $\pm 4\text{g}$, $\pm 8\text{g}$ ou $\pm 16\text{g}$, onde g é uma unidade referenciada pela gravidade ($1\text{g} = 9,8\text{m/s}^2$) e do giroscópio entre os valores de $\pm 250^\circ/\text{s}$, $\pm 500^\circ/\text{s}$, $\pm 1000^\circ/\text{s}$ ou $\pm 2000^\circ/\text{s}$. Essas configurações, assim como aquisição de dados podem ser realizadas por dois meios de comunicação: SPI e I^2C , utilizando a placa de desenvolvimento observada na Figura 15.

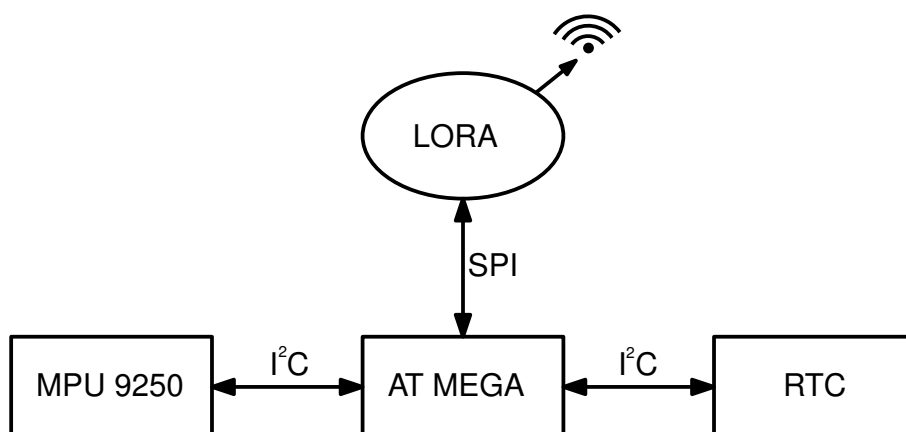
Real Time Clock

Com intuito de propiciar sincronismo da comunicação e também para registro de uma estampa temporal dos dados coletados, o hardware desenvolvido possui um RTC (*Real Time Clock*), DS1307. Este é um circuito integrado de baixo consumo, cerca de 500 nA em repouso, que realiza comunicação I²C, e foi utilizado para proporcionar configuração de data e hora para todos os dispositivos da rede (SEMICONDUCTOR, 2020).

4.2.2 Dispositivo completo

Uma vez especificados os elementos de *hardware*, torna-se necessário uni-los em um único dispositivo. Assim, na Figura 16, observa-se o diagrama do dispositivo.


Figura 16 – Diagrama do dispositivo.



Fonte: Autor.


A placa de circuito impresso montada com os dispositivos pode ser observada nas Figuras 17 e 18, onde são mostradas as vistas superior e inferior do *hardware*.

Figura 17 – Placa desenvolvida (vista superior).



Fonte: Autor.

Figura 18 – Placa desenvolvida (vista inferior).



Fonte: Autor.

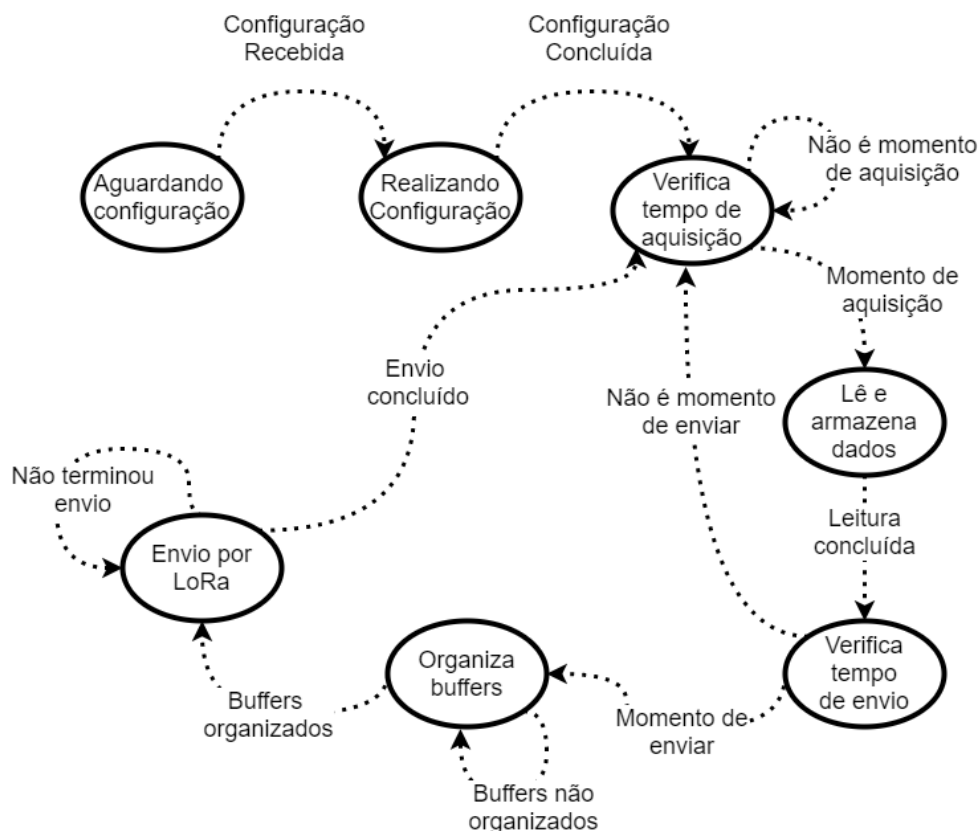
4.3 Comunicação em Rede

A partir do hardware proposto, foi desenvolvido um *firmware* para obter os dados dos sensores e enviá-los via comunicação sem fio para o coletor de dados. A máquina de estados do *firmware* proposto pode ser observada na Figura 19. O dispositivo inicia e fica no estado aguardando configuração, que é recebida através de um software desenvolvido para tal função. A configuração é então gravada no dispositivo específico para animal, incluindo um número de identificação único e um rótulo de categoria do usuário (macho, fêmea ou DIV). Ainda, a configuração serve para colocar o dispositivo em sincronismo com a RSSF, inserindo dados do tempo de aquisição dos dados, além do tempo de publicação de cada dispositivo na rede.

Ao receber os dados de configuração, o dispositivo realiza as etapas internas de configuração e fica pronto para realizar aquisição de dados. O dispositivo realiza a leitura dos sensores, verificando através de uma interrupção interna se é o momento desta realização, e armazena os dados desta leitura. Em seguida, verifica se é o momento de enviar os dados. Nesta etapa, foi estabelecido um procedimento análogo ao modo de comunicação TDMA (*Time Division Multiple Access*), onde cada dispositivo possui o seu momento de publicação da informação, ou seja, cada dispositivo possui um momento específico para enviar os dados para o coletor. Esse tipo de comunicação é realizada por divisão temporal, assim é necessário um relógio de tempo real, conforme o utilizado no dispositivo.

No caso do protocolo de enlace para a rede desenvolvida, foi estabelecido que a publicação é enviada a cada segundo e o número de identificação do indivíduo é o indicador


Figura 19 – Máquina de estado do microcontrolador.



Fonte: Autor.

da publicação. Assim, o dispositivo envia seus dados sempre que o período de transmissão chega no momento referente ao identificador do dispositivo. Por exemplo, em uma rede com 10 (dez) dispositivos e envio de dados a cada 10 (dez) segundos, o dispositivo identificado com 0 (zero), realiza o envio dos seus dados sempre no momento 0 (zero) de cada transmissão, como exemplificado na Figura 20.

Figura 20 – Exemplo de publicação do dispositivo na rede.



Fonte: Autor.

Então, o dispositivo segue realizando leituras nos sensores e guardando essas informações até que seja seu momento de publicação. Quando chega o momento de publicação, o dispositivo realiza uma organização dos dados, inserindo cabeçalho que contém, entre outras coisas, estampa temporal e um CRC (*Cyclic Redundancy Check*) para aumentar a

confiabilidade dos eventos de comunicação. Com esse formato, os dados são encaminhados para camada de física comunicação LoRa, que envia através de RF com frequência de 915MHz para o coletor de dados.

4.4 Aquisição dos Dados

Conforme mencionado na seção anterior, o microcontrolador é responsável por controlar as aquisições de dados, conforme a configuração do sistema. A configuração do dispositivo permite a alteração do tempo de ciclo da máquina de estados, deixando-o configurável quanto ao tempo de aquisição e também ao tempo de publicação da comunicação. Cabe salientar que essa configuração é feita conforme a rede, mantendo um padrão entre os dispositivos. Desta forma, nessa seção serão descritas as condições e necessidades para que essa aquisição ocorra dentro do sistema proposto.

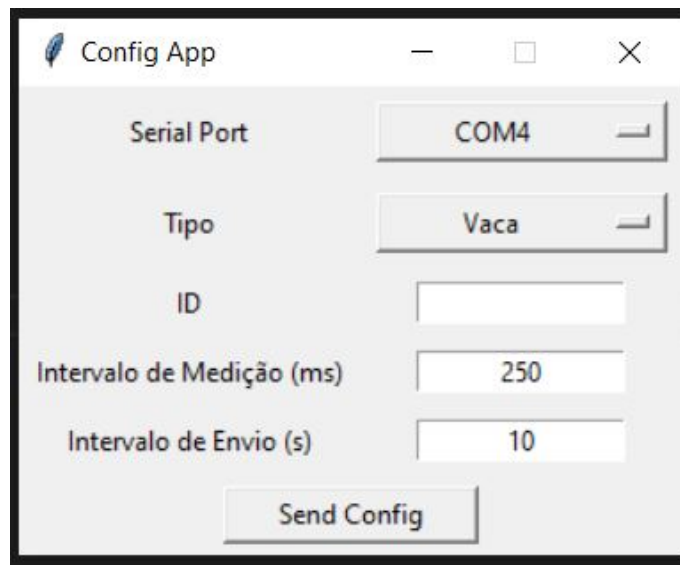
4.4.1 Configurações

As configurações gerais dos dispositivos são duas. A primeira é a configuração dos sensores no que tange à resolução de cada um, e é realizada mediante alteração de *firmware*, o que, mesmo não sendo algo prático, é necessário para garantir a confiabilidade do sistema, limitando algumas configurações. Para o desenvolvimento deste trabalho, estabeleceu-se que o fundo de escala de cada sensor seria $\pm 4g$, $\pm 1000^\circ/s$ e $\pm 4800\mu T$, respectivamente, dos acelerômetros, giroscópio e magnetômetro. Essa configuração foi estabelecida a partir de testes preliminares realizados com o dispositivo, buscando as melhores faixas para cada sensor. Ainda é importante frisar que acelerômetro e giroscópio utilizam os dados em 16 *bits* e o magnetômetro em 14 *bits*, fixando assim a resolução de cada sensor.

A segunda configuração trata dos tempos relacionados à máquina de estados já apresentada na seção anterior. Esses tempos, estão diretamente relacionados ao ciclo de leitura dos sensores, impactando também na quantidade de dados a serem enviados pelo dispositivo LoRa. Esta configuração é realizada a partir de um software desenvolvido exclusivamente para isso. A interface do software pode ser observada na Figura 21.

Esta interface estabelece um enlace de comunicação emulando uma porta serial através de um enlace guiado do tipo USB. Selecionando qual dispositivo será configurado, a interface permite configurar: a categoria do dispositivo (macho, fêmea ou DIV), as opções permitidas, um “ID”, identificador que serve principalmente para o momento de

Figura 21 – Interface de configuração de dispositivo na rede.



Fonte: Autor.

publicação de dados do dispositivo; e o campo de “Intervalo de Envio”, que é referente à periodicidade de publicação da rede. Por fim, a mesma interface ainda permite a configuração do “Intervalo de Medição”, que trata do tempo de aquisição dos dados, ou seja, o tempo do ciclo de leitura dos sensores.

4.4.2 Ciclo de Aquisição

Depois da configuração, o sistema fica pronto para comunicação. Nesse momento, deve ser respeitado o tempo de cada sensor estar disponível para aquisição dos dados. Conforme INVENSENSE (2020), sensores que compõem a placa de desenvolvimento do MPU-9250 precisam de no mínimo 35ms para estarem prontos para leitura. Dessa forma o sistema espera um ciclo de leitura para depois iniciar efetivamente a leitura.

Os dados utilizados nesse trabalho, foram adquiridos em uma configuração de ciclo de 500ms, ou seja, a cada período desse tempo, o sistema realiza uma leitura de cada sensor, e coloca os elementos em um *buffer* para que possam ser enviados posteriormente.

4.4.3 Organização dos dados

A organização dos dados pode ser dividida em duas etapas: preparação para envio, que tange toda parte estruturação dos dados adquiridos e estruturação do *buffer*, e envio dos dados. A outra parte organizacional dos dados são as transformações e ordenamento desses no recebimento da informação, ou seja, todos os processos necessários para deixar


o dado pronto para análise do evento.

A etapa de organização para envio tem início com o processo de aquisição de dados. A aquisição dos dados ocorre em 16 *bits* (acelerômetro, giroscópio e sensor de temperatura) e 14 *bits* (magnetômetro), considerando os 3 eixos de cada sensor acelerômetro, giroscópio e magnetômetro, mais os dados de temperatura. O total de cada ciclo de leitura concatena 10 medidas escalares. Com intuito de minimizar o tamanho do pacote de dados, os mesmos foram transformados para valores de 8 *bits* apenas, considerando a parte mais significativa dentre 2 *bytes*, com, intuito de privilegiar a resolução às variações mais significativas de cada sensor.

Esse processo faz com que o pacote de envio via LoRa tenham seu tamanho reduzido pela metade, possibilitando não apenas uma comunicação mais rápida, mas tornando viável a inclusão de elementos de identificação no pacote como, identificação do indivíduo e do tipo do indivíduo, estampa temporal do dispositivo no envio do pacote, contagem de envios, além de um CRC para aumentar a confiabilidade da rede. Todos esses elementos podem ser inseridos sem preocupação de comprometimento no limite de dados permitidos no pacote LoRa, que é de 255 *bytes*.

Para realização do envio, os dados são organizados sequencialmente. O resultado é um pacote de informação que consiste numa sequência de valores com as medidas de acelerômetro, giroscópio, magnetômetro e temperatura, além dos elementos de identificação supracitados. Uma representação deste pacote de comunicação pode ser visualizada na Figura 22, na qual os elementos são destacados e através de expansão do eixo Z do acelerômetro é possível verificar a sequência de leitura dos dados.

Figura 22 – Modelo de pacote de comunicação inicialmente proposto para os dados dos sensores.




Fonte: Autor.

Tentando minimizar a possível perda da totalidade de dados devido à erros de comunicação, visto que um pacote perdido contém todos os dados de 10 s de todos os sensores,

foi estabelecida uma divisão desse pacote para o envio. Assim, foi estabelecida uma sequência de 4 pacotes enviados sequencialmente. Cada pacote é enviado, contendo apenas a informação de 1 sensor, utilizando um byte para identificação do sensor. O primeiro pacote envia os dados do acelerômetro, o segundo envia os dados de giroscópio, o terceiro envia os dados de magnetômetro e o quarto, os dados de temperatura, conforme mostra a Figura 23.

Figura 23 – Modelo do pacote de comunicação adotado para o sistema proposto.



Fonte: Autor.

Quando o dado é recebido no computador junto ao concentrador, há necessidade de ordenação. Primeiramente realiza-se a tentativa de retornar os dados para as dimensões originais. Sabendo que todos os dados originalmente possuíam 2 bytes, 16 ou 14 bits, e estavam sendo enviados apenas com 1 byte, 8 bits mais significativos. Assim, o byte que chega do dispositivo passa a ser o byte mais significativo, e é adicionado um conjunto de 8 bits de zeros para o byte menos significativo, transformando os dados novamente em 16 bits. Após isto, ocorre realiza-se a conversão dos dados, ainda brutos, para suas respectivas unidades. Assim, os dados de acelerômetro, giroscópio, magnetômetro, passam a ter seus respectivos valores convertidos nas unidades, g, °/s, μT e °C, deixando os dados pronto para o processamento e detecção dos eventos.

4.4.4 Sincronização dos Dados


Com a publicação de cada indivíduo em um instante diferente, conforme explicado na Seção 4.3, é necessário que ocorra uma sincronização dos dados. Nessa etapa, a estampa temporal enviada junto de cada pacote de dados é de suma importância para esta sincronização.

A estampa temporal anexada ao *buffer* é relativa ao momento de envio, ou seja, é o tempo em que a informação foi publicada na rede. Sabendo que há uma quantidade

de dados em cada pacote, a estampa serve para percepção de quando foi o último ciclo de leitura na máquina de estado, indicando o tempo real da última leitura dos sensores. Conhecendo a rede e sabendo o tempo de publicação e de leitura dos dados, é possível rotular individualmente cada dado com a estampa de tempo real de aquisição.

Na Figura 24, tem-se um exemplo da previsibilidade possível conforme o tempo de cada amostra. Considerando um *buffer* publicado com estampa de 13 : 15 : 10, é possível identificar que o último elemento n do *buffer* tem esse tempo. Com essa identificação, cada elemento anterior tem sua marca temporal subtraída pelo tempo de leitura, no caso deste trabalho, $500ms$, até que seja possível estabelecer a estampa no primeiro elemento, deixando todos com rótulos temporais.

Figura 24 – Exemplo de visualização da sincronização dos dados.



Fonte: Autor.

Com todos os dados de todos os indivíduos com o rótulo de tempo agregado, é possível sincronizar os dados de diversos indivíduos mesmo com publicações em diferentes momentos.

4.4.5 Dataset Organizado

O conjunto de dados final, *dataset*, é construído ao final da sincronização descrita anteriormente, seguida de uma rápida reestruturação dos dados em linhas e colunas, sendo as linhas organizadas pelo rótulo temporal, em ordem crescente, e as colunas correspondentes aos dados coletados (IDs e medidas dos sensores). A organização final deste *dataset* nesse formato já busca preparar a informação para ser utilizada no desenvolvimento de modelos de detecção de eventos.

A Figura 25 mostra a estruturação final do *dataset*. Na figura, cada linha representa um tempo relativo a um dispositivo envolvido, associando seus dados na sequência das colunas do *dataset*. Na linha seguinte ainda tem-se o mesmo tempo, contudo relativo a outro indivíduo, ajustando todos seus elementos.

Figura 25 – Recorte do *dataset* organizado.

real_time	dispositivo	temp	accx	accy	accz	gyrox	gyroy	gyroz	magx	magy	magz
2020-11-23 13:42:00.000	macho_2	33.215686	-3.031357	-3.843870	3.875120	-984.405280	1000.000000	984.405280	-4650.0	-4808.203125	-5177.34375
2020-11-23 13:42:00.000	femea_2	31.647059	-3.375113	3.906249	-3.218738	-992.217899	1000.000000	-1000.000000	4800.0	4491.796875	-5177.34375
2020-11-23 13:42:00.000	div_femea_2	35.960784	-3.343862	3.937499	-3.249989	1000.000000	1000.000000	-1000.000000	4800.0	4641.796875	-5177.34375
2020-11-23 13:42:00.000	macho_1	34.000000	3.937499	-3.250111	-3.749996	-992.217899	968.749523	968.780041	4800.0	4641.796875	-5177.34375
2020-11-23 13:42:00.500	macho_2	33.215686	-3.031357	-3.750118	-3.968750	-976.592660	1000.000000	-984.374762	-4650.0	-4808.203125	-5177.34375
...
2020-11-23 13:42:59.000	macho_2	33.215686	-3.031357	-3.906371	3.875120	1000.000000	1000.000000	-1000.000000	-4650.0	-4808.203125	-5177.34375
2020-11-23 13:42:59.500	div_femea_2	36.352941	-3.468864	3.718746	3.187610	1000.000000	1000.000000	-1000.000000	4800.0	4641.796875	4272.65625
2020-11-23 13:42:59.500	macho_2	33.215686	-3.031357	-3.906371	3.875120	1000.000000	1000.000000	-1000.000000	-4650.0	-4808.203125	-5177.34375
2020-11-23 13:42:59.500	macho_1	34.000000	3.874998	-3.062608	-3.812497	1000.000000	992.187381	-1000.000000	4800.0	4641.796875	-5177.34375
2020-11-23 13:42:59.500	femea_2	31.647059	-3.187610	3.468742	-3.781247	1000.000000	1000.000000	-1000.000000	4800.0	4491.796875	-5177.34375

Fonte: Autor.

Com essa organização, é possível a utilização das técnicas de tratamento de dados, para que seja possível o êxito do trabalho na identificação do processo reprodutivo dos animais.

4.5 Identificação dos Eventos

Pode-se interpretar o problema de detecção dos eventos como um problema de detecção de evento raro em séries temporais. Cada instante de tempo discreto traz informações de diferentes indivíduos (no cenário em questão, 3 indivíduos) e cada indivíduo produz 10 informações diferentes.

Entretanto, é importante ressaltar alguns desafios no desenvolvimento do modelo:

- A perda de pacotes durante as comunicações na RSSF gera dados ausentes ao longo das linhas e colunas da série temporal;
- O evento é raro, ou seja, na maior parte do tempo não está acontecendo, e quando acontece, tem uma duração curta (alguns segundos);
- O número amostras discretas de tempo para compor uma janela que deve ser classificada pelo modelo pode influenciar no desempenho do modelo e na sensibilidade do modelo à ocorrência do evento.

4.5.1 Interpolação dos Dados

Como ocorre em toda rede de comunicação, a RSSF desenvolvida apresenta eventos de perdas de pacotes de dados. Isso foi minimizado com as mudanças realizadas nos pacotes de dados, conforme descrição da Seção 4.4.3. Contudo essas perdas criam lacunas de informações, visto que foram rotulados todos os dados temporalmente, conforme descrição na Seção 4.4.4. Desta forma, com a intenção de aproximar a sequência dos dados, utilizou-se uma interpolação dos dados para preencher as lacunas deixadas pelos pacotes perdidos.

A interpolação consiste em determinar uma função que melhor ajuste os referidos dados ausentes. A intenção da utilização de interpolação não trata apenas de estimar uma função, mas baseado em alguns dados, encontrar uma aproximação que torne possível estimar outros pontos que não são conhecidos (DORNELLES FILHO, 2016). Com base nisso, o intuito é complementar os dados de cada indivíduo, baseando-se no conjunto adquirido destes. É importante que os dados preenchidos sejam consistentes com o comportamento das variáveis, observando sua conexão com os dados existentes. Caso contrário, pode-se estar inserindo muito ruído nessas posições ausentes do conjunto de dados.

4.5.2 Pré Processamento

Em geral, ao se trabalhar com conjuntos de dados “crus”, é necessário primeiramente aplicar algumas transformações e pré-processamento para auxiliar nos métodos de análise de séries temporais. A padronização de um conjunto de dados pode auxiliar muito os estimadores de aprendizagem de máquina.

Uma técnica bastante utilizada é transformar a escala das diferentes variáveis do sistema para uma faixa comum de valores. Assim, para esse trabalho optou-se por utilizar um pré-processamento *StandardScaler*. Esse método tem o viés de tentar padronizar os dados, removendo a média e escalonando-os para gerar uma dispersão (desvio padrão) unitária. Para tal, o método utiliza como base a equação (8), onde μ é média das amostras e s é o desvio padrão destas amostras.

$$z = \frac{x - \mu}{s} \quad (8)$$

Assim a centralização e o dimensionamento acontecem independentemente em cada tipo de dado do *dataset*, computando as estatísticas relevantes nas amostras no conjunto de treinamento¹.

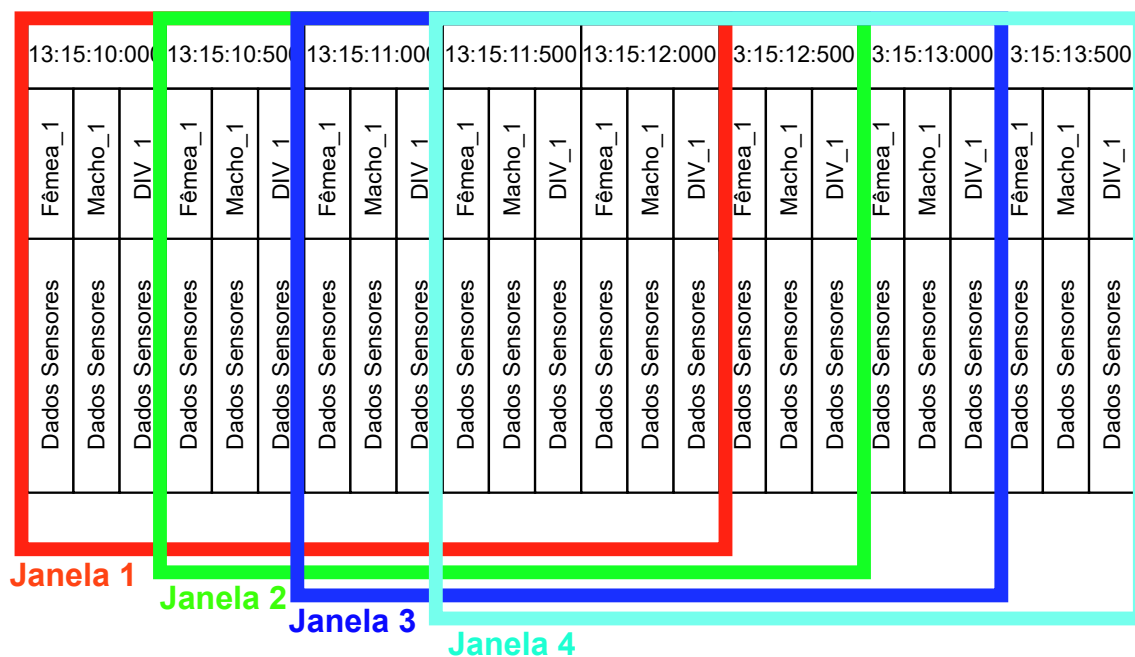
4.5.3 Janelamento dos Dados

Depois do pré-processamento, há a necessidade de rotular os eventos relacionados às atividades de reprodução dos animais, que são a variável alvo que deve ser estimada (ou classificada) neste trabalho. Cabe ressaltar que cada vetor de dados possui apenas 500ms. Embora o evento alvo de observação tenha curta duração, suas reações nos sensores e sua assinatura nos dados são visualmente caracterizadas por mais tempo.

Diante disso, criou-se um sistema de janelamento do *dataset*. Esse sistema, agrupa dados de diferentes indivíduos em uma janela de tempo. Essa janela deslizante, percorre por todo *dataset* passo a passo, janelando os dados em grupos. Tanto o tempo da janela, que indica seu tamanho, quanto o passo para percorrer o *dataset* tornaram-se configuráveis para análise do melhor recorte.

Com as análises dos dados e na configuração da rede, estabeleceu-se que o janelamento indicado seria de uma janela de tempo de 2,5s, onde são 5 vetores temporais e um passo de 500ms, pulando apenas uma amostra temporal e percorrendo todo *dataset*. Esse recorte pode ser observado no exemplo da Figura 26, que demonstra a ideia proposta de janelamento realizando recortes observacionais.

¹ Os parâmetros de normalização calculados com o conjunto de dados de treino devem ser salvos, para que seja possível aplicar uma transformação idêntica em novos dados futuros, inclusive no *dataset* de teste. Esse procedimento evita que novas transformações sejam realizadas com dados de teste/validação, o que geraria um fenômeno chamado *data leakage*, enviesando o modelo.

Figura 26 – Janelamento dos dados do *dataset*.

Fonte: Autor.

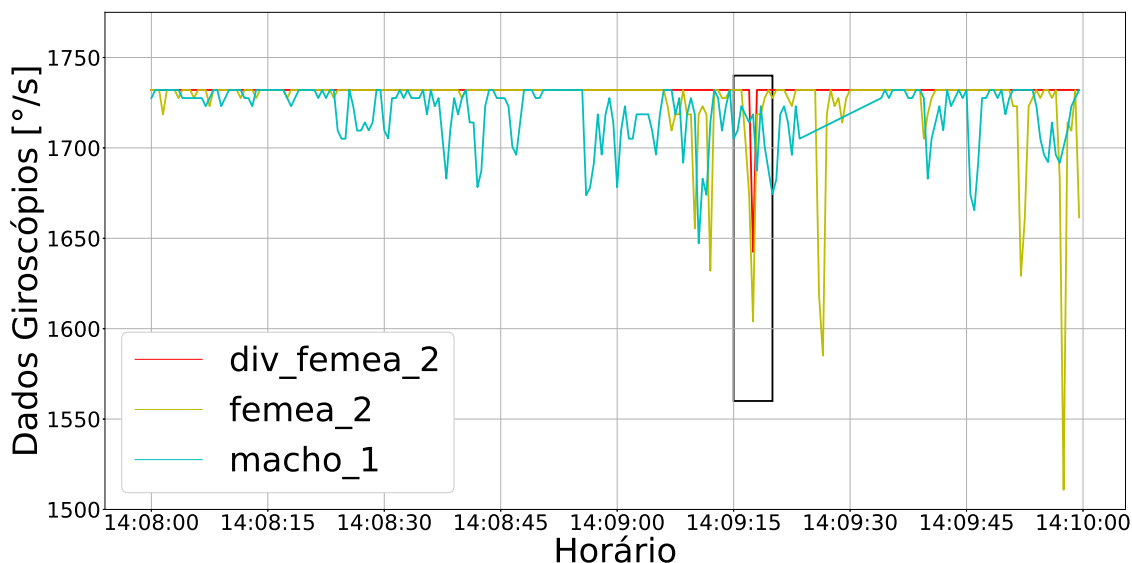
4.5.4 Rotulamento dos eventos de reprodução

Os dados dos animais foram adquiridos em medições realizadas em campo. Durante as atividades de campo, foram anotados os horários de ocorrência dos eventos de reprodução (montas) entre os animais. Posteriormente, como forma de verificação, os dados foram analisados dentro das janelas correspondentes a essas anotações, conforme o exemplo que pode ser observado na Figura 27, que apresenta dados de sensores utilizados para identificação do evento.

Com base nessas anotações, a identificação visual (em campo, durante a aquisição dos dados) e a identificação gráfica, realizou-se o rotulamento dos eventos no conjunto de dados janelados. Essa observação também leva em conta que entre todas as fases do evento de cópula entre os animais, o processo pode levar até 20 segundos, utilizando então esse tempo para janelamento dos dados.

Todas as janelas temporais do *dataset* que se sobrepõem ao intervalo correspondente aos 20 segundos de ocorrência do evento serão rotuladas como “1”, ou seja, como evento verdadeiro, e o restante como “0”, evento falso.

Figura 27 – Exemplo de identificação de evento de reprodução através dos dados obtidos pelo sistema proposto.



Fonte: Autor.

4.5.5 Inserção de Casos

Como o evento de interesse se trata de um evento reprodutivo (o ato do evento de reprodução dos animais), esse torna-se um evento muito raro no universo de amostras do *dataset*. No universo do *dataset*, menos de 1% dos dados são relativos ao evento de interesse. Assim, algumas inserções de dados artificiais para treinamento foram usadas a fim de balancear melhor o conjunto de dados de treino. Esse procedimento é chamado de *data augmentation* na literatura de aprendizagem de máquina (GOODFELLOW; BENGIO; COURVILLE, 2016). No caso deste trabalho, só há interesse em aumentar as amostras dos intervalos entre os eventos, ou seja, os rotulados como 1.

Uma estratégia simples para aumentar o número de amostras dos dados seria copiá-las e modificar ligeiramente a escala das variáveis (multiplicando por um escalar, por exemplo). Entretanto, isso mantém uma correlação muito forte com os dados originais. Em HUANG *et al.* (2019), os autores mostram diversas técnicas para realização do *data augmentation*. Para este trabalho, Assim, optou-se por criar cópias das amostras com inserção de ruído, foi utilizado um ruído gaussiano nas amostras de dados de interesse, ou seja, no evento de reprodução, para o aumento do *dataset*. A relação sinal para ruído dessas cópias é controlada com um parâmetro s , correspondente à potência do ruído, conforme a seguinte equação (9), onde $s(\text{dB})$ é a intensidade deste ruído entre -30dB e

−1dB, com 50 níveis de intensidade diferentes.

$$s = \sqrt{10^{\frac{s(\text{dB})}{10}}} \quad (9)$$

Com os diferentes níveis de ruídos, utilizou-se um vetor aleatório ($\text{data}_{\text{rand}}$), do mesmo tamanho dos dados equivalentes ao evento verdade ($\text{data}_{\text{true}}$), para ser somado aos dados dos eventos verdadeiros, criando um novo cenário para esses elementos. Assim, aumentou-se a quantidade de amostras para treinamento com 50 cópias com ruído para cada janela original de evento de reprodução. Na equação (10), é mostrado como fica o novo dado para evento verdadeiro, conforme a descrição acima.

$$\text{newdata}_{\text{true}} = \text{data}_{\text{true}} + \sum_{n=1}^{50} (\text{data}_{\text{true}} + s_n * \text{data}_{\text{true}}) \quad (10)$$

Com as adequações descritas anteriormente, o *dataset* ficou mais equilibrado para utilização de métodos de aprendizagem supervisionada, passando a ter um percentual de aproximadamente 23% de eventos verdadeiros, tornando a utilização dos métodos de aprendizagem de máquinas com melhor desempenho.

4.5.6 Utilização dos Métodos

Com o *dataset* organizado e equilibrado, é necessária a utilização das técnicas de aprendizagem de máquina para a treinamento e teste da detecção do evento de interesse. Para tal, foram utilizadas quatro técnicas de aprendizagem supervisionada: regressão logística, classificação bayesiana gaussiana, árvore de decisão e máquinas de vetor de suporte. Como já mencionado anteriormente, a intenção é a comparação dos métodos e verificação da eficácia de cada um conforme cada cenário a ser apresentado no capítulo 5.

Foram separados os elementos de treino e teste, sendo 20% dos dados para teste, onde estes testes elementos não entram nos exemplos de treinamento do modelo, permitindo observar a ocorrência de vício nos dados de treino (*overfitting*²). Contudo, os dados originais de eventos positivos (desconsiderando os dados artificiais, usados apenas no treino) possuem poucas amostras, devido a raridade do evento. Assim, foram separadas metade

²*Overfitting* ocorre quando o modelo se adaptou muito bem aos dados com os quais está sendo treinado, porém, não generaliza bem para novos dados. Ou seja, o modelo “decorou” o conjunto de dados de treino, mas não aprendeu de fato o que diferencia aqueles dados para quando precisar enfrentar novos testes (GOODFELLOW; BENGIO; COURVILLE, 2016)

dessas amostras positivas para treino e a outra metade para teste.

Com a separação, os elementos de evento positivo de treino passam pelos processos descritos na seção anterior, com intuito de equilibrar o *dataset* de treino. Mesmo assim, observe que não foram inseridos tantos dados artificiais ao ponto de se chegar a 50% de casos positivos. Portanto, a fim de dar mais peso para os erros do tipo falsos negativos, utilizou-se um valor de peso w para a classe positiva (classe 1). Essa variável pode ser parametrizada em todas as técnicas que foram utilizadas neste trabalho. Essa ponderação age como um peso no cálculo da função objetivo dos modelos, dando mais força para os erros do tipo falso negativo, auxiliando no treinamento, buscando o nível adequado de eficiência do sistema.

Buscando avaliar o desempenho dos modelos, estes serão comparadas entre si. Assim, são observados cenários com ponderação dos pesos do evento binário variando entre 50% e 95% de peso para a classe do evento positivo, sendo seu valor complementar ($1 - w$) atribuído para classe do evento negativo.

Ainda, para avaliação de desempenho das técnicas, as divisões supracitadas entre treino e teste, realizadas utilizando uma técnica de elementos aleatórios, serão realizadas 200 rodadas de validação cruzada, ou seja, separações aleatórias diferentes. Essas rodadas de comparações serão avaliadas na forma de histogramas, permitindo comparar não apenas o desempenho médio dos modelos, mas a sua dispersão a depender da divisão dos dados. Ainda os melhores e os piores desempenhos serão salvos, para serem utilizados como análise de desempenho, permitindo investigar qual a divisão dos elementos favorece ou prejudica cada técnica abordada.

5 ESTUDO DE CASO


Neste capítulo serão descritos resultados do estudo de caso realizado para validar o desenvolvimento deste trabalho. Na Seção 5.1 é descrito o primeiro teste em campo deste trabalho. Em seguida, na Seção 5.2, é descrito o procedimento de aquisição do *dataset* discutindo algumas observações sobre o mesmo. Na Seção 5.3 são construídos cenários para tratamento dos dados. A alteração no processamento dos dados é uma importante forma de avaliação do desempenho do sistema, assim, na Seção 5.4 são analisadas essas mudanças. Por fim, na Seção 5.5, a influência dos dados de cada indivíduo na capacidade de detecção do evento é avaliada.

5.1 Testes Iniciais

Os primeiros testes foram realizados com hardware desenvolvido anteriormente pelo grupo de pesquisas, diferente do descrito anteriormente. O hardware antigo acondicionado dentro do DIV é mostrado na Figura 28.

Este hardware era um *spin off* de um produto desenvolvido pelo grupo em parceria com a empresa E-AWARE (2021). Além de um transceptor sub-gigahertz, este hardware é composto por microcontrolador ARM Cortex M0, facilitando a configuração, programação e uso em diversas aplicações (NXP, 2014). Entretanto, alguns problemas foram detectados. Além do *hardware* possuir apenas acelerômetro e sensor de temperatura, o que poderia ser insuficiente para as demandas deste trabalho, os testes de campo mostraram que o rádio não possuía o alcance do enlace de comunicação em uma distância necessária para a aplicação. Isto fez com que ocorressem perdas consideráveis de pacotes de comunicação, mostrando a necessidade do desenvolvimento de um novo *hardware*, o qual foi objeto deste trabalho e descrito na Seção 4.2.


Figura 28 – Hardware antigo no DIV aberto.



Fonte: Autor.

Por outro lado, mesmo que o *hardware* não fosse o adequado, o teste foi importante para possibilitar a observação das assinaturas dos eventos de reprodução. Para simplificação na época, os dados são apenas a soma vetorial dos 3 eixos (x, y e z) do acelerômetro, mas, ainda assim, o evento é observável.

Figura 29 – Recorte temporal dos dados, unindo sensor do macho e DIV.




Fonte: Autor.

Na Figura 29, é possível visualizar no evento A os pontos de aceleração devida à

movimentação do macho, com um ponto de aceleração em destaque. Da mesma forma, no evento C, tem-se um evento de aceleração mais acentuada devida ao movimento do macho, em conjunto com um evento de aceleração de menor intensidade no DIV. Ainda na Figura 29, no evento B, têm-se o evento de aceleração do DIV sem ocorrência direta de evento devido ao macho, e isso se deve ao fato da monta ter sido realizada por um macho sem colar. Na Figura 30, é possível observar o evento considerando o colar da fêmea com o DIV, sendo possível perceber as características do evento.

Figura 30 – Recorte temporal dos dados, unindo sensor da fêmea e DIV.



Fonte: Autor.

Este teste preliminar mostrou parte das características dos eventos de observação. Ainda, levou à necessidade do desenvolvimento de um novo *hardware*, sendo, portanto, de grande valia para este trabalho.

5.2 Análises Iniciais

Com o desenvolvimento do novo hardware, os primeiros testes foram realizados em um fazenda parceria, no município de Júlio de Castilhos. Neste teste, foi utilizado um modelo de colares com velcro conforme é possível observar, no pescoço dos animais, na Figura 31. Contudo, não foi possível realização dos testes do evento de reprodução neste momento, devido ao ciclo estral dos animais.

Figura 31 – Foto dos testes realizados em Júlio de Castilhos.



Fonte: Autor.

Assim, houve a necessidade de novos testes. Estes testes ocorreram na Estação Experimental Agronômica da UFRGS e focaram na observação dos eventos, buscando identificação da assinatura de sinal referente ao evento de monta e, também na aquisição de dados para formar um conjunto de elementos para serem utilizados nas análises do problema. Empregando um modelo de colar misto entre tecido de sarja e velcro para ser mais confortável para os animais. Este modelo de colar, pode ser observado na Figura 32.

Os principais eventos relacionados aos testes preliminares são descritos na Tabela 3. O detalhamento é feito com base nos eventos 1, 7 e 8, por se tratarem de eventos de interesse, assim sendo utilizando nas legendas os nomes dos dispositivos como *macho_1*, *femea_1* e *div_femea_1*, relativos aos dispositivos que aparecem nos dados.

Nas Figuras 33 e 34 é possível observar os dados absolutos dos três eixos do giroscópio e acelerômetro, respectivamente, referentes ao evento inicial, onde o macho não vestia o colar com o sensor. Mesmo assim, é importante observar o registro do impacto registrado no DIV, impacto esse causado pela atividade reprodutiva do macho. O impacto fica mais característico nos dados de giroscópio, mas são observados também nos dados de acelerometria.

Figura 32 – Foto do colar utilizado nos testes da UFRGS.



Fonte: Autor.


Tabela 3 – Descrição dos principais eventos.

Evento	Horário	Descrição
1	13:37	Evento de reprodução sem sensor do macho
2	13:42	Tentativa de evento de reprodução com Macho 2
3	13:43	Tentativa de evento de reprodução com Macho 2
4	13:45	Tentativa de evento de reprodução com Macho 2
5	13:46	Tentativa de evento de reprodução com Macho 2
6	14:04	Evento de reprodução com Macho 1
7	14:09	Evento de reprodução com Macho 1
8	14:13	Evento de reprodução com Macho 1
9	14:22	Tentativa de evento de reprodução com Macho 2
10	14:24	Tentativa de evento de reprodução com Macho 2

Para que seja possível observar o evento completo, foram selecionados dois intervalos de ocorrência dos eventos de reprodução. No primeiro intervalo, é possível observar os dados de giroscópio e acelerômetro nas Figuras 35 e 36. No segundo, os dados podem ser observados nas Figuras 37 e 38.

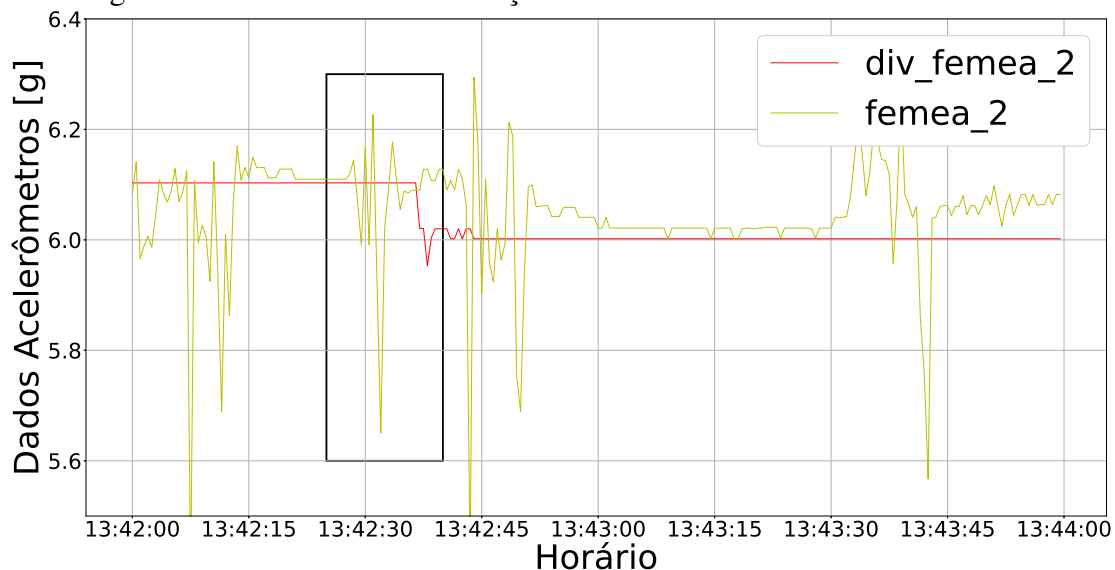
Nas figuras, a movimentação do macho fica bem caracterizada. Isso pode estar diretamente relacionado com a característica do evento, com necessidade de um salto do

Figura 33 – Monta sem identificação do macho - Dados do giroscópio.



Fonte: Autor.

Figura 34 – Monta sem identificação do macho - Dados do acelerômetro.




Fonte: Autor.

macho sobre a fêmea, sendo possível visualizar as tentativas de ocorrência deste, até a consumação do ato, detectada pelo dispositivo intravaginal. Ainda, ao final do evento, o macho reduz suas movimentações, reduzindo as oscilações nos sensores.

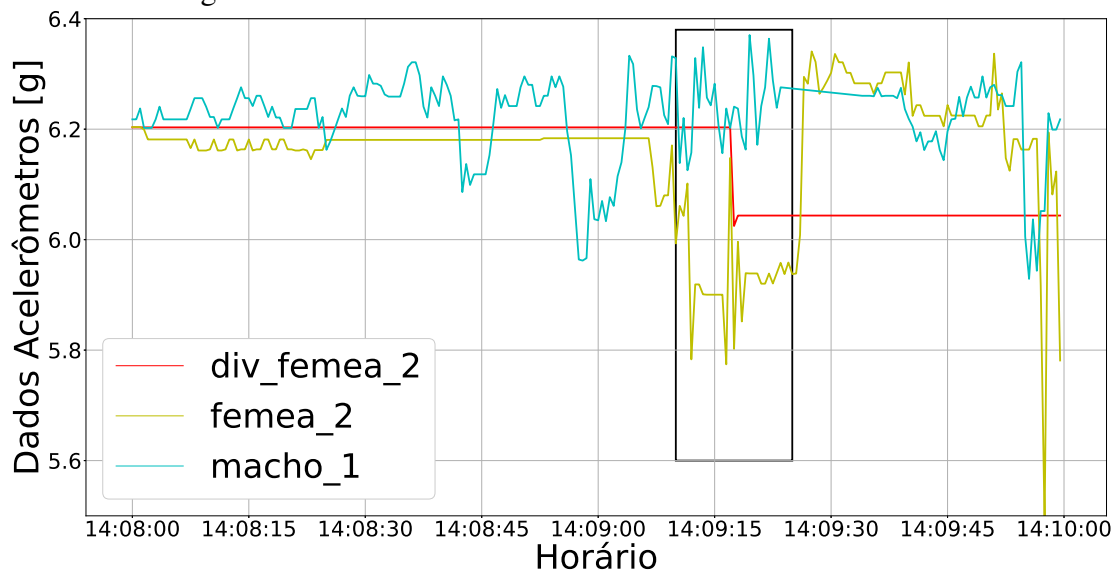
Da mesma forma, é importante caracterizar as ações de movimentação indicadas pelos sensores na fêmea, que ocorrem, principalmente, no momento anterior e logo em seguida à penetração peniana. Esses eventos podem indicar assinaturas do sinal, ou seja, momentos que ajudam a caracterizar o ato como: forte evento de impacto no DIV, indicativo de

Figura 35 – Monta identificada 1 - Dados do giroscópio.



Fonte: Autor.

Figura 36 – Monta identificada 1 - Dados do acelerômetro.




Fonte: Autor.

salto ou inclinação brusca do pescoço do macho; e, ainda, movimento de tranco frontal da fêmea em seguida ao ato.


No momento anterior ao impacto, a assinatura pode ser relacionada com as tentativas do macho, bem próximo, e depositando o próprio o peso sobre a fêmea. Nos momentos posteriores, as oscilações podem ser associadas ao empurrão dado pelo macho devido ao impacto no momento da cópula.

Figura 37 – Monta identificada 2 - Dados do giroscópio.



Fonte: Autor.

Figura 38 – Monta identificada 2 - Dados do acelerômetro.



Fonte: Autor.

5.3 Seleção de Variáveis de Entrada

Com os dados de entrada adquiridos e com o rotulamento manual do sinal de assinatura dos eventos de monta, passa-se a analisar as melhores possibilidades de detecção automática dos eventos. Para isso, foram utilizados alguns cenários de mudanças na leituras dos dados, para verificação e análise de qual configuração pode produzir o melhor resultado baseado nos mesmos modelos.

Todas as abordagens de combinações de variáveis foram realizadas com a mesma

configuração. O recorte dos dados tem tamanho de 2,5 segundos por janela e com passo de 0,5 segundos, inserção de 50 amostras artificiais de dados com rótulo positivo para o evento durante o treinamento dos modelos e 80% de peso para classe positiva do evento.


A melhor forma encontrada para análise dos dados foi a partir histogramas. Para tal, os modelos de previsão foram treinados e testados num processo de validação cruzada com 200 repetições, utilizando um separador que possibilita análises com divisões diferentes do *dataset* em conjuntos de treino e teste, e criando a separação dos exemplos de maneira aleatória.

5.3.1 Cenário 1 - Dados originais

Para o cenário 1, serão utilizados as 10 variáveis enviadas, os 3 eixos de acelerômetro, giroscópio e magnetômetro, mais o sensor de temperatura. Foram utilizados os 4 modelos anteriormente apresentados, ou seja, regressão logística, classificador de Bayes, decisão em árvore e SVC.

Na Figura 39 é apresentado o histograma de sensibilidade e da taxa de acerto ao evento, considerando o cenário exposto. Essa figura representa a taxa de acerto da classe 1, o evento de monta, ou seja, mostra quanto cada modelo acerta. Assim, nas abscissas é apresentado o valor da métrica correspondente, enquanto nas ordenadas o quantitativo de ocorrências no “bin” correspondente do histograma, visto que foram realizadas 200 rodadas de testes.

Figura 39 – Histograma da sensibilidade dos modelos considerando todos elementos.




Fonte: Autor.

Com base no histograma da Figura 39, é possível observar o baixo desempenho de praticamente todos os modelos à métrica de sensibilidade, reforçando que esta métrica corresponde à razão entre total de verdadeiros positivos e o total de classificações positivas na saída do modelo (incluindo falsos negativos). Ou seja, é justamente a “taxa de sensibilidade” do modelo à ocorrência do evento positivo.

Desta forma, o melhor modelo para esse cenário seria o classificador em árvore, contudo, mesmo esse ainda possui um desempenho médio considerado ruim, com média de 48,44% e intervalo de confiança na faixa de 21,6 a 75,3% de sensibilidade na maioria das tentativas. Para complementar esse cenário, a Figura 40 mostra a taxa de falsos positivos dos modelos. Esse resultado mostra um baixo índice de alarmes falsos, que estão na média abaixo de 2,5%.

Figura 40 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando todos elementos.



Fonte: Autor.

Os resultados anteriores eram esperados de certa forma, visto que se está trabalhando com um conjunto de dados desbalanceado, onde o maior número de exemplos são rótulos negativos, sendo os eventos positivos muito raros.

5.3.2 Cenário 2 - Adição de valores absolutos


Diante do primeiro cenário, alguns elementos podem ser adicionados como variáveis de entrada com intuito de melhorar os resultados. Desta forma, para o cenário 2, foram mantidos os 10 elementos utilizados no cenário 1, ou seja, 3 eixos de acelerômetro, gi-

roscópio e magnetômetro, mais o sensor de temperatura. Contudo, foram adicionados os valores absolutos dos sensores de 3 eixos. Esses valores absolutos são retirados a partir de uma soma vetorial simples, representada na equação (11).

$$\text{valor}_{\text{abs}} = \sqrt{\text{valor}_x^2 + \text{valor}_y^2 + \text{valor}_z^2} \quad (11)$$

Assim, com os valores absolutos, os dados de entrada agora são 13 valores por cada estampa temporal. Diante deste cenário, os 4 modelos são analisados, conforme Figura 41. Neste cenário, é possível observar que, com exceção do decisor em árvore, todos os demais modelos apresentam um deslocamento do histograma para a direita, indicando maiores médias da métrica analisada. Isso indica que a composição das novas *features* a partir de uma função não-linear das *features* originais pode contribuir para a classificação do evento.

Figura 41 – Histograma da sensibilidade dos modelos considerando todos elementos mais valores absolutos.



Fonte: Autor.


5.3.3 Cenário 3 - Utilização apenas de valores absolutos

Com a melhoria de alguns modelos com a inserção dos valores absolutos no cenário 2, o cenário 3 tem o propósito de avaliar a influência destes valores. Assim, são utilizados apenas os valores absolutos para teste, totalizando 4 elementos, valores absolutos de acelerômetro, giroscópio e magnetômetro, além do dado de temperatura. São duas as

motivações para esta estratégia: reduzir a dimensionalidade dos sinais de entrada, o que pode futuramente ainda facilitar a comunicação na rede de sensores, e também eliminar variáveis fortemente correlacionadas, visto que isso pode trazer problemas de multicolinearidade.

Com base no histograma da sensibilidade ao evento, na Figura 42 é possível visualizar uma melhora significativa no desempenho médio do modelo de Bayes, onde o valor médio encontra-se na faixa dos 90% de acerto, oscilando entre 75 e 100%. Também é notável a relativa evolução do modelo SVC, com o uso dos valores absolutos, chegando à faixa de 45 a 80% de sensibilidade.


Figura 42 – Histograma da sensibilidade dos modelos considerando todos elementos com valores absolutos.



Fonte: Autor.

Na Figura 43, é apresentada a taxa de falsos positivos que o modelo gera, usando apenas as *features* de intensidade das medidas dos sensores. Este diagrama de caixas é complementar ao histograma anterior, visto que para que o modelo de Bayes tenha um desempenho alto de sensibilidade, ele também gera falsos positivos de maneira mais significativa, enquanto os outros modelos possuem menor número de acertos, mas também geram menos falsos positivos. O modelo SVC possui uma taxa bem menor de falsos positivos, mesmo que possua uma taxa menor de sensibilidade que Bayes.

Figura 43 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando todos elementos com valores absolutos.



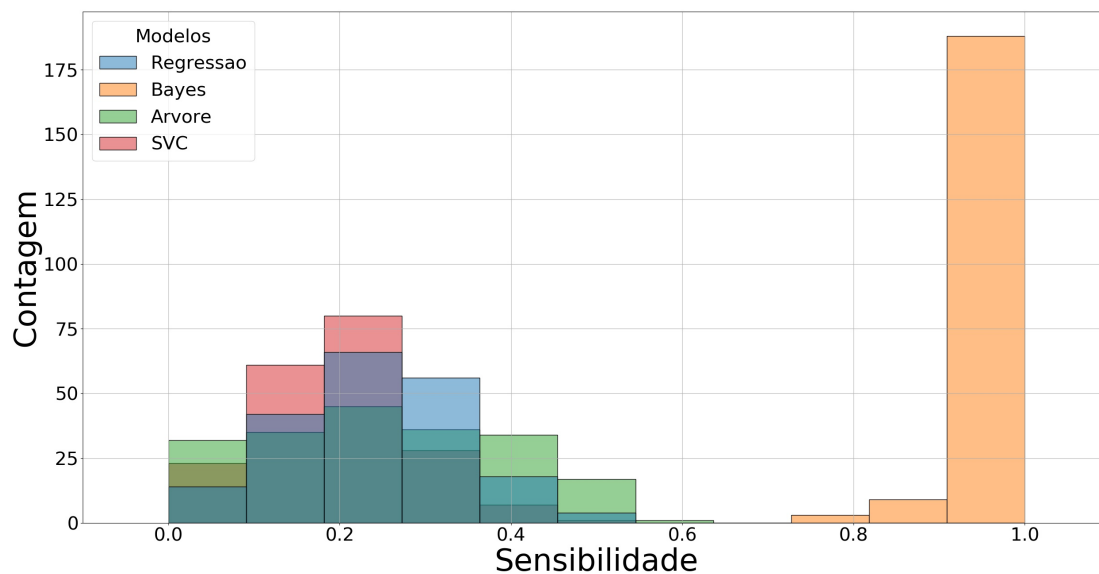
Fonte: Autor.

5.3.4 Cenário 4 - Exclusão dos dados de temperatura

Apenas para observabilidade da influência, o cenário 4 propõem repetir o cenário 3, mas sem a inclusão da temperatura. Isso ocorre pelo entendimento de que a temperatura não é um fator que caracteriza o evento propriamente dito, assim é necessário verificar se esse parâmetro tem influência ou não dos resultados dos modelos. Na Figura 44 é possível observar os acertos dos modelos conforme o cenário proposto. Observando o histograma, é visível que os modelos levavam em consideração a temperatura, e isso mostra que a maioria deles teve um desempenho médio inferior ao retirar este dados.

Contudo, o modelo de Bayes melhorou significativamente. Essa relação pode estar relacionada com a estabilidade dos dados de temperatura, visto que, esses mostram a temperatura do ambiente onde o animal, na média, com exceção do DIV que mostra a temperatura interna no animal. Desta forma, esta estabilidade poderia criar um “falso” dado para os modelos. O modelo baseado em Bayes acaba por melhorar com essa remoção, porque tem sua lógica baseada em probabilidade do evento, e a estabilidade pode interferir nessa análise. Ainda sobre este cenário, cabe salientar que todos os modelos acabam errando mais. Na Figura 45 é possível observar que a taxa de falsos positivos de todos aumentou e o modelo de Bayes chegou ao intervalo de confiança entre 26 a 33% de falsos positivos. É importante salientar, que a temperatura dos sensores, apesar de terem


Figura 44 – Histograma da sensibilidade dos modelos considerando valores absolutos sem dados de temperatura.



Fonte: Autor.

efeito significativo no que tange o evento de reprodução, o sensor de temperatura pode ser utilizado para outros comportamentos dos animais, como monitoramento do cio das fêmeas ou o vigor físico nos machos (se ficam ou não parados ao sol, por exemplo).

Figura 45 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando valores absolutos sem dados de temperatura.




Fonte: Autor.

5.3.5 Cenário 5 - Utilização apenas de giroscópio e acelerômetro

Com a ideia de retirar elementos, o cenário 5 tem a proposta de análise da utilização apenas de dados de aceleração e velocidade angular, assim, utilizando apenas dados do acelerômetro e do giroscópio. Na Figura 46 observa-se o desempenho dos modelos quando são considerados apenas os referidos dados.

Figura 46 – Histograma da sensibilidade dos modelos considerando apenas giroscópio e acelerômetro.




Fonte: Autor.

É possível observar que o histograma do modelo de Bayes possui o melhor desempenho nesse cenário, enquanto os outros modelos não conseguem uma eficiência significativa. Ainda, para análise do conjunto dos elementos, na Figura 47 é possível visualizar a relação da taxa de falsos positivos de cada modelo, caracterizando novamente, que o Bayes acerta os eventos verdadeiros, mas também erra nos exemplos negativos.


Ainda, para verificação foram realizados testes considerando apenas os valores absolutos do giroscópio e acelerômetro. Na Figura 48, é possível observar que nesse caso a influência dos valores absolutos não são tão significativas, fazendo com que os modelos tenham, praticamente, o mesmo desempenho entre dados crus e dados absolutos.

Figura 47 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando apenas giroscópio e acelerômetro.



Fonte: Autor.


Figura 48 – Histograma da sensibilidade dos modelos considerando apenas valores absolutos de giroscópio e acelerômetro.



Fonte: Autor.

Contudo, quando trata-se da taxa de falsos positivos, mostrados na Figura 49, percebe-se que os modelos aumentaram esse fator com o uso de dados absolutos, e fica visível o aumento, principalmente da regressão logística. Porém Bayes acaba mantendo-se estável na faixa de erros, errando para menos na maioria das tentativas.

Figura 49 – Diagrama de caixa da taxa de falsos positivos dos modelos considerando apenas valores absolutos de giroscópio e acelerômetro.



Fonte: Autor.

5.3.6 Resumo das Seleção das Variáveis de Entrada

Com as mudanças nas variáveis de entrada é possível chegar à conclusão de que torna-se necessária uma avaliação geral dos cenários apresentados. Assim, na Tabela 4 tem-se o resumo das sensibilidades para todos os modelos, considerando os modelos propostos. Grifados em verde, são os melhores cenários para cada modelo. Ainda, cabe salientar, que foi usado como métrica de intervalo de confiança como 2 desvios padrão para cima e dois para baixo.

É possível analisar que o melhor cenário trata-se do cenário 4, onde são usadas as variáveis em valores absolutos sem a utilização dos dados de temperatura, e, neste cenário, o modelo de Bayes tem destaque, considerando que possui uma média de sensibilidade de 97,75%.

Tabela 4 – Sensibilidade dos modelos conforme seleção das variáveis de entrada.

modelos	Métricas	Cenário 1	Cenário 2	Cenário 3	Cenário 4	Cenário 5.a	Cenário 5.b
Regressão	Média da Sensibilidade	0.3175	0.3004	0.3846	0.4333	0.1865	0.2592
	Desvio Padrão	0.0936	0.0952	0.1046	0.1104	0.0908	0.1034
	Intervalo de Confiança	0.1303 - 0.5047	0.1099 - 0.4909	0.1755 - 0.5937	0.2125 - 0.6541	0.0048 - 0.3681	0.0523 - 0.4660
Bayes	Média da Sensibilidade	0.0442	0.1148	0.9269	0.9775	0.7481	0.7379
	Desvio Padrão	0.0456	0.0504	0.105	0.0435	0.1062	0.1056
	Intervalo de Confiança	0 - 0.1353	0.0139 - 0.2157	0.717 - 1.0	0.8906 - 1.0	0.5358 - 0.9605	0.5267 - 0.9492
Árvore	Média da Sensibilidade	0.4844	0.4181	0.3808	0.4021	0.2448	0.1906
	Desvio Padrão	0.1343	0.1223	0.1749	0.1189	0.1021	0.1256
	Intervalo de Confiança	0.2158 - 0.7529	0.1735 - 0.6627	0.0310 - 0.7306	0.1644 - 0.6398	0.0405 - 0.4491	0 - 0.4418
SVC	Média da Sensibilidade	0.1919	0.2856	0.5871	0.5694	0.0871	0.0679
	Desvio Padrão	0.0823	0.0928	0.0998	0.1065	0.0582	0.0504
	Intervalo de Confiança	0.0273 - 0.3564	0.01 - 0.4713	0.3874 - 0.7868	0.3564 - 0.7824	0 - 0.2035	0 - 0.1687

5.4 Alterações no Processamento dos dados

Na seção anterior foi proposto avaliar o desempenho dos modelos a partir de processamentos estáticos, ou seja, a avaliação dos dados a partir do mesmo janelamento, do mesmo modelo de inserção de eventos de reprodução, e do mesmo peso de classes. Nesta seção, o intuito é mostrar algumas opções de alterações possíveis. Desta forma, são utilizados os dados com valores absolutos e sem a variável temperatura, para comparação entre as diferentes técnicas.

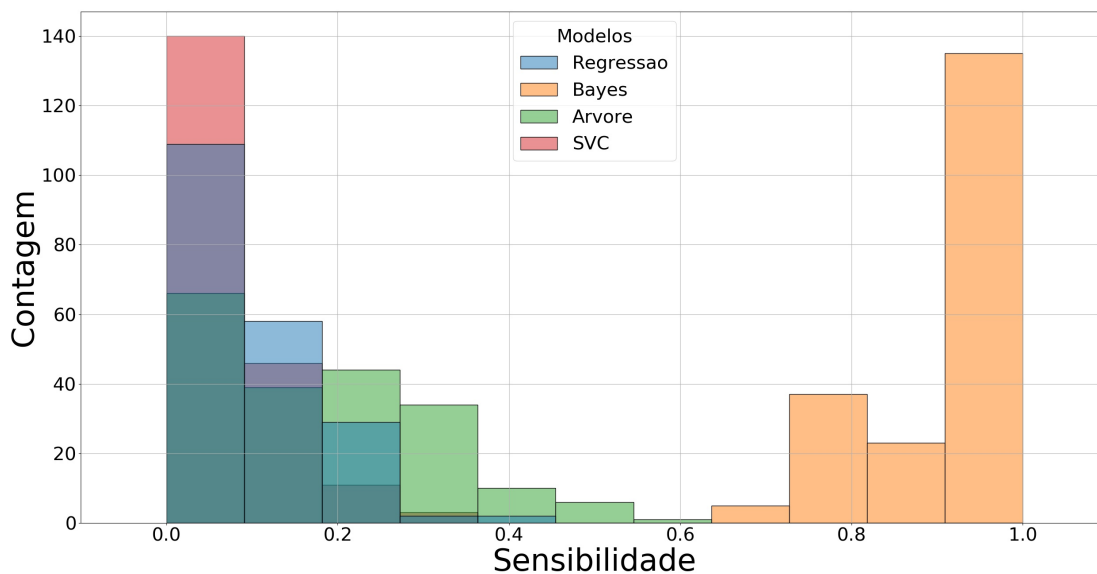
5.4.1 Mudanças no Janelamento dos Dados

O recorte em janelas dos dados, padrão proposto do trabalho até este momento, foi uma janela temporal de 2,5 segundos e um passo de deslize desta janela de 0,5 segundos. Assim, mantendo os outros itens estáticos, a proposta é a alteração destas variáveis de recorte dos dados para avaliação de desempenho dos modelos.

Na Figura 50, pode-se observar a avaliação dos dados para uma alteração de passo para 1 segundo, mantendo o tamanho da janela em 2,5 segundos. No histograma, onde é possível observar a sensibilidade dos modelos, é visível que apenas Bayes consegue manter um desempenho satisfatório com essa alteração de passo. Já os outros modelos apresentam uma redução de desempenho. Na Figura 51, é possível observar que a taxa de falsos positivos não sofre alterações significativas em relação com o passo original.


A proposta de alteração no recorte dos dados passa por uma alteração mútua, mudando o tamanho da janela para 5 segundos, ou seja, dobrando o tamanho da mesma e seguindo com o passo de 1 segundo, conforme apresentado anteriormente. Assim, na Figura 52,

Figura 50 – Histograma da sensibilidade dos modelos com janela de dados para 2,5 segundos e passo de 1 segundo.



Fonte: Autor.

Figura 51 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 2,5 segundos e passo de 1 segundo.

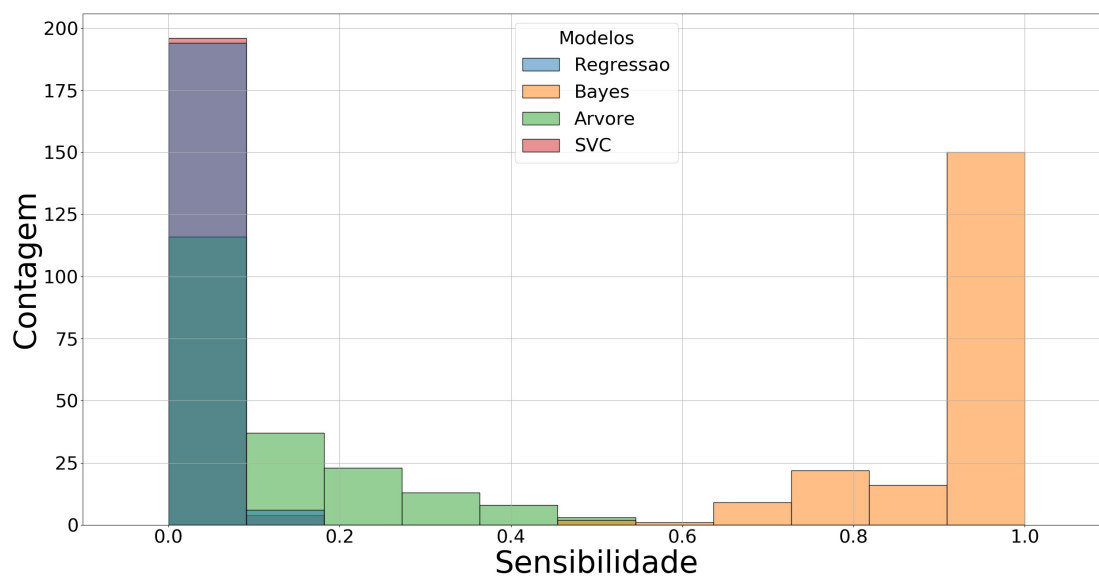


Fonte: Autor.

pode-se observar o desempenho dos modelos com esse cenário.

Na Figura 53, fica caracterizada a sensibilidade dos modelos, e, nesse caso, consegue-se perceber que modelos como SVC e regressão logística são muito prejudicados com uma janela maior, tendo seu desempenho degradado em relação aos cenários já observados. Contudo, os demais modelos, Bayes e classificador em árvore, mantêm seus de-


Figura 52 – Histograma da sensibilidade dos modelos com janela de dados para 5 segundos e passo de 1 segundo.



Fonte: Autor.

sempenhos, a única ressalva é observado no histograma que apresenta a taxa de falsos positivos. Neste caso, Bayes acaba errando mais com esse tipo de janela e os outros modelos conseguem manter aproximadamente as mesmas taxas de erros.

Figura 53 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 5 segundos e passo de 1 segundo.




Fonte: Autor.

Ainda com a proposta de mudança no recorte, é importante a observação de um re-

corde mínimo, e, neste caso, optou-se pela observação do recorte de janela com passo e tamanho de 0,5 segundos. Desta forma, na Figura 54 é possível observar os resultados para esse cenário. No histograma da figura é possível observar que há uma melhora no desempenho dos modelos, enquanto Bayes ainda possui o melhor desempenho, SVC e regressão logística possuem apresentam uma melhora significativa de desempenho. Cabe salientar que esses modelos também acabam errando mais nos casos negativos e isso fica claro isso a partir da observação do histograma da Figura 55.


Figura 54 – Histograma da sensibilidade dos modelos com janela de dados para 0,5 segundos e passo de 0,5 segundos.



Fonte: Autor.

É possível observar que o melhor cenário trata-se da janela de 0,5 segundos com passo de 0,5 segundos. Isto porque, quanto melhor o tamanho da janela, maior a quantidade de janelas o que faz auxiliar alguns modelos em melhorar o aprendizado. Pode-se observar isto de maneira mais clara na Tabela 5, onde o resumo das sensibilidades para os janelamentos são apresentados.

Figura 55 – Diagrama de caixa da taxa de falsos positivos dos modelos com janela de dados para 0,5 segundos e passo de 0,5 segundos.



Fonte: Autor.

Tabela 5 – Sensibilidade dos modelos conforme do janelamento dos dados.


Algoritmos	Métricas	Tamanho 2,5 - Passo 1	Tamanho 5 - Passo 1	Tamanho 0,5 - Passo 0,5
Regressão	Média de Sensibilidade	0.1254	0.0281	0.5118
	Desvio Padrão	0.0837	0.0424	0.1173
	Faixa de Confiança	0.0 - 0.2929	0.0 - 0.1128	0.2772 - 0.7463
Bayes	Média de Sensibilidade	0.9108	0.9158	0.9585
	Desvio Padrão	0.1043	0.1080	0.0403
	Faixa de Confiança	0.7023 - 1.0	0.6999 - 1.0	0.8778 - 1.0
Árvore	Média de Sensibilidade	0.1946	0.1171	0.3308
	Desvio Padrão	0.1380	0.1293	0.1803
	Faixa de Confiança	0.0 - 0.4706	0.0 - 0.3758	0.0 - 0.6914
SVC	Média de Sensibilidade	0.0938	0.0249	0.4013
	Desvio Padrão	0.0759	0.0402	0,1023
	Faixa de Confiança	0.0 - 0.2455	0.0 - 0.1053	0.1967 - 0.6058

5.4.2 Alteração na Quantidade de Eventos de Reprodução

A proposta de inserção de eventos de reprodução tem o intuito de ampliar o universo de treino dos modelos, conforme explicado na seção 4.5.5. Esta ampliação mostrou-se necessária e satisfatória para o desempenho apresentados anteriormente. Contudo, é necessária a observação de quando isso pode afetar o desempenho dos modelos. Assim, a proposta apresentada nesta seção é a realização de alterações no quantitativo dessas inserções, mantendo fixos os outros elementos, e, utilizando os dados de valores absolutos

e sem temperatura, avaliar apenas a influência da inserção destes dados no processo.

Figura 56 – Histograma da sensibilidade no evento sem adição de eventos no treinamento.



Fonte: Autor.


A Figura 56 traz os resultados sem adição de eventos de reprodução utilizando apenas os dados adquiridos, mas sempre separando aleatoriamente entre treino e teste, conforme mencionado anteriormente neste trabalho. Assim, neste caso é possível observar que alguns modelos são prejudicados significativamente, como exemplos, SVC e regressão logística.

Com a utilização de 10 eventos extras, ou seja, adicionando 10 cópias dos exemplos positivos que foram artificialmente somadas a um ruído aleatório aos dados de treino brutos, conforme a Figura 57 apresenta. Nesta figura, percebe-se a adição de monta favoreceu principalmente a regressão logística, que passou a acertar mais o evento.

Para esse comparativo, foram adicionados 25 eventos reprodutivos no treino dos modelos. Através da Figura 58, pode-se observar que a inclusão de mais casos favorece os modelos. Praticamente todos os modelos tem evolução na média das 200 rodadas, mostrado no histograma da figura.


Por fim, para exemplificar com menor e maior adição de eventos, este cenário propõe a análise da utilização de 75 janelas de eventos no treinamento dos modelos. A Figura 59 apresenta o desempenho de tais modelos. Assim, com a adição destas janelas, há uma saturação de quanto o dado torna-se útil para os modelos, fazendo com que tenha-se apenas uma repetição dos estímulos aos modelos, semelhante a um *overfitting*.

Figura 57 – Histograma da sensibilidade no evento com adição de 10 eventos no treinamento.



Fonte: Autor.


Figura 58 – Histograma da sensibilidade no evento com adição de 25 eventos no treinamento.



Fonte: Autor.

Tratando-se da quantidade de eventos inseridos, sem a inserção os modelos testados não alcançam com desempenho, visto que o evento é de alta raridade, tornando um problema para aprendizagem supervisionada. Porém, a inserção de janelas de eventos de reprodução, é importante para melhorar os modelos, visto que amplia o cenário do evento no treinamento. Contudo, a grande inserção de eventos, pode gerar problemas, seme-

Figura 59 – Histograma da sensibilidade no evento com adição de 75 eventos no treinamento.



Fonte: Autor.

lhante a um *overfitting*. O resumo destes cenário, pode ser observado na Tabela 6

Tabela 6 – Sensibilidade dos modelos conforme inclusão de eventos de reprodução para treinamento.

Algoritmos	Métricas	0 eventos	10 eventos	25 eventos	75 eventos
Regressão	Média de Sensibilidade	0.0096	0.1529	0.2079	0.2569
	Desvio Padrão	0.00194	0.0728	0.0836	0.0915
	Faixa de Confiança	0.0 - 0.0484	0.0073 - 0.2985	0.0406 - 0.3752	0.0740 - 0.4398
Bayes	Média de Sensibilidade	0.8165	0.9802	0.9775	0.9775
	Desvio Padrão	0.1512	0.0395	0.0437	0.0435
	Faixa de Confiança	0.5141 - 1.0	0.9012 - 1.0	0.8902 - 1.0	0.8906 - 1.0
Árvore	Média de Sensibilidade	0.2585	0.1904	0.2279	0.2675
	Desvio Padrão	0.1269	0.1801	0.1422	0.1371
	Faixa de Confiança	0.0048 - 0.5123	0.0 - 0.5506	0.0 - 0.5122	0.0 - 0.5418
SVC	Média de Sensibilidade	0.0	0.1327	0.1842	0.2175
	Desvio Padrão	0.0	0.0653	0.0762	0.0812
	Faixa de Confiança	-	0.0020 - 0.2634	0.0318 - 0.3365	0.0550 - 0.3800


5.4.3 Alteração no Peso das Classes

Conforme mencionado anteriormente, a classe do evento observado possui pouca repetibilidade. Assim, para análise até o momento, foi atribuído um peso de 80% para a classe do evento, conforme descrito nas seções anteriores. Isso faz com que os modelos

analisados levem em consideração mais a classe do evento que a classe do “não-evento”. Contudo é importante avaliar o quanto esse peso de classes pode influenciar a decisão dos modelos.

Desta forma, no conceito de alterar o peso da classe do evento, inicia-se pela redução dela, deixando-a com peso inferior a classe do “não-evento”. Para isso, conforme a Figura 60 foi utilizado um peso de 40% para classe positiva do evento. Conforme já mencionado em outros casos, o modelo de Bayes não é afetado, em partes, com a mudança dos pesos das classes. Por outro lado, os demais modelos são afetados significativamente.

Figura 60 – Histograma da sensibilidade no evento com peso de 40% para classe 1.




Fonte: Autor.

A situação de influência do peso das classes com o evento, em muito, pode estar relacionada com a raridade do evento. Isso faz que com pouco peso para o evento dito raro, a maioria dos modelos não conseguem encontrar realmente a situação. Isso pode ser avaliado também na Figura 61, onde tem-se 50% de peso para classe 1, teoricamente equilibrando os eventos, mas como eles são desbalanceados na raridade, estes ainda não conseguem evolução suficiente para apresentarem resultados expressivos.

Com o aumento do percentual do peso da classe do evento, os modelos avaliados atingem aos poucos melhores desempenhos. A Figura 62 possibilita a análise do resultado dos modelos utilizando um peso de 60% para classe do evento. Novamente, cabe salientar que Bayes mantêm-se pouco afetado com a mudança dos pesos das classes, mas os demais modelos tem progressões conforme aumenta o peso da classe de maior raridade, no caso


Figura 61 – Histograma da sensibilidade no evento com peso de 50% para classe 1.



Fonte: Autor.

deste estudo, a classe do evento em si.

Figura 62 – Histograma da sensibilidade no evento com peso de 60% para classe 1.




Fonte: Autor.

Por fim, para salientar que o aumento do peso da classe do evento é realmente significativo, na Figura 63 é possível observar os resultados dos modelos considerando um peso para classe do evento de 95%. Contudo, os outros modelos, demonstram evolução considerável com o aumento das classes.

É importante observar nos resultados que o modelo de Bayes não sofre alteração signi-

Figura 63 – Histograma da sensibilidade no evento com peso de 95% para classe 1.



Fonte: Autor.

ficativa com a mudança dos pesos das classes, demonstrando o aprendizado deste modelo. O resumo destas variações pode ser observado na Tabela 7. Cabe salientar que não parece adequado utilizar em todos os testes um nível tão elevado de peso para uma classe. Mesmo sendo um evento raro, a inclusão de casos utilizando ruído, conforme exemplificado nas seções anteriores, auxiliam do desempenho dos modelos. Por isso utilizou-se 80% para a maioria dos testes, por esse índice alcançar um meio termo entre eficiência e representatividade.

Tabela 7 – Sensibilidade dos modelos conforme alteração no peso da classe do evento.


Algoritmos	Métricas	Peso de Classe 40	Peso de Classe 50	Peso de Classe 60	Peso de Classe 95
Regressão	Média de Sensibilidade	0.0969	0.1198	0.1567	0.4333
	Desvio Padrão	0.0598	0.0679	0.0776	0.1104
	Faixa de Confiança	0.0 - 0.2165	0.0161 - 0.2557	0.0014 - 0.3119	0.2125 - 0.6541
Bayes	Média de Sensibilidade	0.9775	0.9775	0.9775	0.9775
	Desvio Padrão	0.0435	0.0435	0.0435	0.0435
	Faixa de Confiança	0.8906 - 1.0	0.8906 - 1.0	0.8906 - 1.0	0.8906 - 1.0
Árvore	Média de Sensibilidade	0.0002	0.0019	0.02	0.4021
	Desvio Padrão	0.002	0.0105	0.0429	0.1189
	Faixa de Confiança	0.0 - 0.006	0.0 - 0.0228	0.0 - 0.1058	0.1644 - 0.6398
SVC	Média de Sensibilidade	0.0302	0.0567	0.09	0.5694
	Desvio Padrão	0.0363	0.0462	0.0604	0.1065
	Faixa de Confiança	0.0 - 0.1028	0.0 - 0.1491	0.0 - 0.2109	0.3564 - 0.7824

5.5 Alterações nos Indivíduos Observados

O último estudo necessário é a verificação da eficácia dos modelos caso não sejam utilizados os dados do DIV. Acredita-se que esse estudo seja importante, visto que o DIV é um dispositivo invasivo ao animal e, se possível fosse, seria mais adequado viabilizar o trabalho sem a utilização do mesmo, preservando ainda mais o bem-estar do animal. Assim, foi avaliado o cenário dos valores absolutos sem a temperatura, cenário esse que até o momento mostrou-se como o de melhor valor médio de sensibilidade dos modelos. Foi utilizado o tamanho de janela de 2,5 segundos e com passo de 0,5 segundos, ou seja, 5 dados com passo de 1 dado, além da inclusão de 50 dados com ruídos para treino e peso de 80% para classe de evento positivo.

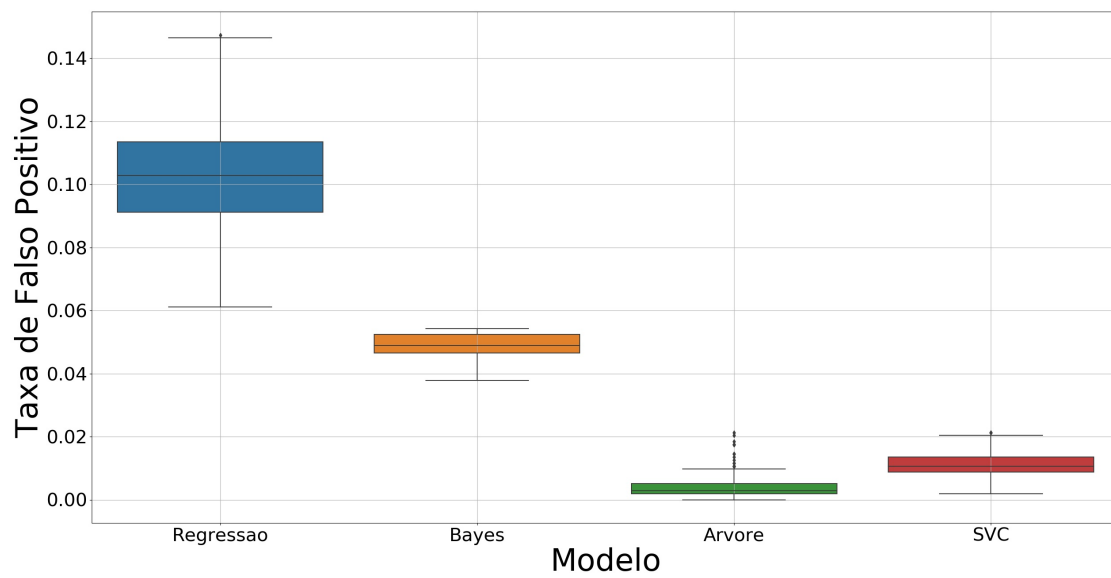
Na Figura 64, é possível observar que a sensibilidade dos modelos sem a inclusão do DIV fica muito prejudicada. Isso demonstra a forte influência do DIV na detecção do evento, sendo o principal dado, visto que carrega a característica do impacto na fêmea. Ainda, para constar, no diagrama de caixas da Figura 65, percebe-se que alguns modelos têm a taxa de falsos positivos aumentado. Acredita-se que sem os dados do DIV, outros eventos não-rotulados podem causar confusão com o evento da monta, acarretando em baixo desempenho dos modelos.

Figura 64 – Histograma da sensibilidade sem inclusão do DIV.



Fonte: Autor.

Figura 65 – Diagrama de caixas da taxa de falsos positivos sem inclusão do DIV.



Fonte: Autor.

6 CONCLUSÕES

O trabalho apresentado teve sua principal motivação a partir de uma solicitação do grupo de veterinária da Universidade Federal do Rio Grande do Sul, que buscava uma solução inovador para o monitoramento de bovinos. A intenção era estabelecer um sistema capaz de realizar o monitoramento do comportamento destes animais, adquirindo dados necessários para isso. Com os dados, o sistema deveria estabelecer uma identificação dos comportamentos dos animais, principalmente no quesito reprodução, buscando a identificação se houve ou não o evento durante a cópula.

Partindo desta premissa, o trabalho tratou do desenvolvimento de um *hardware* vestível nos animais para aquisição dos dados e inferência da ocorrência ou não do evento em questão. Com os dados adquiridos, foram utilizados algoritmos de aprendizagem supervisionada para detecção do evento. Esses algoritmos, foram comparados entre si, levando em conta quais os dados relevantes a serem utilizados, avaliando mudanças na maneira de processamento dos dados e qual a influência dos indivíduos envolvidos na detecção do evento. Diante desta análise, o trabalho buscou esclarecer qual a melhor técnica de *machine learning*, de aprendizagem supervisionada para utilização na RSSF proposta.

O estudo realizado com os dados adquiridos pelo hardware desenvolvido mostrou ser possível a identificação do evento desejado, alcançando altas taxas de sensibilidade na detecção correta, associadas a taxas relativamente pequenas de falsos positivos. Obteve-se uma comparação entre quatro algoritmos amplamente empregados na área de *machine learning*, ressaltando os méritos de cada um.

Os testes realizados enfatizaram primeiramente a alteração de variáveis, como a utilização dos valores totais ou absolutos dos elementos que poderiam afetar os modelos de aprendizagem supervisionada. Na sequência, foram realizadas alterações no processamento dos dados, janelamento, quantidade de eventos inseridos para treinamento dos

modelos e alteração no peso das classes, visando sempre a análise destas variações nos modelos utilizados. Por fim, foi realizada a avaliação da utilização dos dados do DIV para o aprendizado dos modelos.

Como conclusão, afirma-se que os melhores resultados obtidos foram devidos à utilização dos valores absolutos dos dados do giroscópio, acelerômetro e magnetômetro, juntamente com um janelamento de 2,5 segundos com passo de 0,5 segundos, inserção de 50 janelas extras para treinamento dos modelos e peso de classe de 80% para classe do evento. Isto principalmente para o modelo de Bayes, que alcançou sensibilidade média de 97,75% com uma taxa de falsos positivos com média inferior a 30%.

Por fim, é importante salientar que a avaliação do uso do DIV realmente mostrou-se um diferencial importante para as métricas utilizadas, ou seja, o dispositivo intravaginal é de fato necessário para obtenção de bons resultados com o sistema desenvolvido.

6.1 Contribuições da Dissertação

O desenvolvimento do *hardware* e a implementação da RSSF foram passos fundamentais para desenvolvimento deste trabalho. Da mesma forma, foram relevantes os testes realizados para definição da possibilidade de detecção do evento de interesse, avaliando as diversas possibilidades de utilização dos dados a partir da variação das *features* de entradas, mudanças de pré processamento e ainda análise da importâncias dos indivíduos para o cenário. Acredita-se que outra contribuição foi a utilização da comparação entre 4 métodos de aprendizagem supervisionada para avaliação dos resultados obtidos. Outra contribuição considerada importante deste trabalho, é o *dataset* adquirido, visto que este poderá ser utilizado em outros estudos e trabalhos futuros.

6.2 Trabalhos Futuros

Como trabalhos futuros a partir desta dissertação, sugere-se duas áreas de concentração: *hardware* e RSSF e análise dos dados.

Sobre *hardware* e RSSF, este trabalho fez uso dos dispositivos desenvolvidos apenas para obtenção dos dados do processo de reprodução dos animais. Um estudo mais amplo sobre autonomia de energia do dispositivo é necessário, fazendo com que seja possível aquisição de dados de longo prazo, além da utilização real dos dispositivos em campo.

Ainda, um estudo sobre a utilização de outra topologia de rede pode ser objeto de estudos, com a possibilidade de todos os dispositivos realizarem um *relay* com seus assemelhados, ampliando o alcance da rede sem necessidade de alteração no hardware desenvolvido.

Quanto a análise dos dados, sugere-se que seja realizada uma análise mais metódica de seleção de *features*, utilizando técnicas como *shap*, *selectKbest* ou *recursive feature elimination* (RFE), possibilitando um melhor desempenho dos algoritmos. Ainda, considerar um modelo que seja capaz de lidar com previsões de dados sequenciais, como redes neurais recorrentes ou *long short-term memorys* (LSTM), por exemplo, para que seja possível levar em consideração a evolução dos parâmetros ao longo do tempo ao invés de trata-los separadamente, como colunas independentes de previsão.

Por fim, cabe ressaltar a importância de estudos futuros sobre a análise de técnicas de filtragem na borda, ou seja, técnicas que podem ser utilizadas dentro do próprio dispositivo, podendo assim refinar os dados adquiridos e/ou minimizar a transmissão desses. Além disso, ressalta-se a utilização de uma classificação com um grupo maior de indivíduos, buscando maior número de exemplos de monta, melhorando assim o *dataset* e ainda possibilitando um estudo da identificação dos indivíduos envolvidos.

REFERÊNCIAS

- ACAR, C.; SHKEL, A. **MEMS Vibratory Gyroscopes**. EUA: Springer, 2008. 270 p.
- ALLIANCE, L. **LoRaWAN® Specification v1.0.2**. Disponível em: <<https://lora-alliance.org/resource-hub/lorawanr-specification-v102>>. Acesso em: 26/08/2020.
- ANDREJAŠIČ, M. **MEMS Accelerometers**. 2008. 17 p. Trabalho de Conclusão de Curso (Graduação) — Faculdade de matemática e física. Departamento de física. Universidade de Liubliana, Liubliana, 2008.
- BARUSELLI, P. *et al.* Manipulation of follicle development to ensure optimal oocyte quality and conception rates in cattle. **Reproduction in Domestic Animals**, [S.l.], v. 47, p. 134–141, 2012.
- BEEBY, S. *et al.* **MEMS mechanical sensors**. EUA: Artech House, 2004. 269 p.
- BOCQUIER, F. **Method and device for automatically detecting mating of animals**. US Patent 7,992,521.
- BOISSY, P. *et al.* Monitoring mobility assistive device use in post-stroke patients. *In: ANNUAL INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY, 29., 2007, Lion, França. Proceedings [...]* IEEE, 2007. p. 4372–4375.
- BUSCH, P.; STĪPMANN, F.; EWALD, H. Determination of standing-time of dairy cows using 3D-accelerometer data from collars. *In: ELEVENTH INTERNATIONAL CONFERENCE ON SENSING TECHNOLOGY (ICST), 2017., 2017. Proceedings [...]* [S.l.: s.n.], 2017. p. 1–4.
- BUSCH, P.; STĪPMANN, F.; EWALD, H. Signal processing and behaviour recognition in animal welfare monitoring system. *In: IEEE INTERNATIONAL CONFERENCE ON THE SCIENCE OF ELECTRICAL ENGINEERING IN ISRAEL (ICSEE), 2018., 2018. Anais [...]* [S.l.: s.n.], 2018. p. 1–4.
- CAMARGO, J. F. C. **Desenvolvimento de tecnologia de hardware e software para o monitoramento de animais**. 2019. 78 p. Dissertação (Mestrado) — Programa de Pós Graduação Profissional em Matemática, Estatística e Computação Aplicadas à Indústria, Universidade de São Paulo (USP), São Carlos, 2019.

DATTA, S. *et al.* Automated Scoring of Hemiparesis in Acute Stroke from Measures of Upper Limb Co-ordination using Wearable Accelerometry. **IEEE Transactions on Neural Systems and Rehabilitation Engineering**, [S.l.], 2020.

DORNELLES FILHO, A. A. **Fundamentos de cálculo numérico**. Porto Alegre: Bookman Editora, 2016. 192 p. v. 2.

E-AWARE. **E-Aware Technologies**. Disponível em: <<https://www.eaware.com.br>>. Acesso em: 20/01/2021.

FENG, Y. *et al.* A localized inter-actuator network topology repair scheme for wireless sensor and actuator networks. **China Communications**, [S.l.], v. 16, n. 2, p. 215–232, 2019.

FORSTER, A. **Introduction to wireless sensor networks**. EUA: John Wiley & Sons, 2016. 192 p.

GARCIA, A. R. *et al.* Comportamento de fêmeas bovinas de corte em pastagens sem arborização. **Circular Técnica**, [S.l.], v. 82, p. 9, 2018.

GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. EUA: MIT Press, 2016. 800 p.

HONDA, H.; FACURE, M.; YAOHAO, P. **Os Três Tipos de Aprendizado de Máquina**. Disponível em: <<https://lamfo-unb.github.io/2017/07/27/tres-tipos-am/>>. Acesso em: 20/12/2020.

HOPERF. **RFM95W - LoRa Module**. Disponível em: <<https://www.hoperf.com/modules/lora/RFM95.html>>. Acesso em: 26/08/2020.

HUANG, L. *et al.* Data augmentation for deep learning-based radio modulation classification. **IEEE Access**, [S.l.], v. 8, p. 1498–1506, 2019.

INVENSENSE. **MPU-9250 Product Specification, Revision 1.1**. Disponível em: <<https://invensense.tdk.com/products/motion-tracking/9-axis/>>. Acesso em: 06/09/2020.

JOSEPH, S. *et al.* Wearable assistive device for human motion and health monitoring. *In*: INTERNATIONAL CONFERENCE ON INTELLIGENT SUSTAINABLE SYSTEMS (ICISS), 2019., 2019, Palladam, India. **Proceedings [...]** IEEE, 2019. p. 437–440.

KLEINBAUM, D. G. *et al.* **Logistic regression**. EUA: Springer, 2002. 722 p.

LI, P. *et al.* Research on data privacy protection algorithm with homomorphism mechanism based on redundant slice technology in wireless sensor networks. **China Communications**, [S.l.], v. 16, n. 5, p. 158–170, 2019.

LISBOA, P. C.; GAMOU, J. O.; ZUBELZU, E. M. **System and device for monitoring the reproductive activity of animals**. US Patent App. 15/538,489.

LISKA, G. R. **Classificação de dados em modelos com resposta binária via algoritmo boosting e regressão logística**. 2012. 106 p. Dissertação (Mestrado) — Programa de Pós Graduação em Estatística e Experimentação Agropecuária, Universidade Federal de Lavras (UFLA), Lavras, 2012.

LOUREIRO, A. A. *et al.* Redes de sensores sem fio. *In: SIMPÓSIO BRASILEIRO DE REDES DE COMPUTADORES (SBRC), 2003. Proceedings [...]* [S.l.: s.n.], 2003. p. 179–226.

MENEGASSI, S. *et al.* Behavioral assessment during breeding soundness evaluation of beef bulls in Rio Grande do Sul. **Anim. Reprod**, [S.l.], v. 8, n. 3/4, p. 77–80, 2011.

MICROCHIP. **MegaAVR® Data Sheet**. Disponível em:
<<https://www.microchip.com/wwwproducts/en/ATmega328P#datasheet-toggle>>.
Acesso em: 06/04/2020.

MITCHELL, T. M. **Artificial Neural Networks**. EUA: McGraw-Hill Education, 1997. 432 p.

MÜLLER, I.; MENEGASSI, S. R. O. **Sistema e método de monitoramento de comportamento e atividade reprodutiva de animais em rebanho**. BR 102018005455-4 A2.

NAVLANI, A. **Support Vector Machines with Scikit-learn**. Disponível em:
<<https://www.datacamp.com/community/tutorials/svm-classification-scikit-learn-python>>. Acesso em:
20/01/2021.

NXP, S. **KW01 Development Hardware**. Disponível em:
<<https://www.nxp.com/docs/en/reference-manual/KW01DHRM.pdf>>. Acesso em:
20/08/2020.

PINTO, D. **Bayesian Classification with Regularized Gaussian Models**. 2015. 150 p. Dissertação (Mestrado) — Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal de Minas Gerais (UFMG), Belo Horizonte, 2015.

PRIMDAHL, F. The fluxgate magnetometer. **Journal of Physics E: Scientific Instruments**, [S.l.], v. 12, n. 4, p. 241, 1979.

RIBEIRO JUNIOR, E. E. **Estratégias para Classificação Binária. Um estudo de caso com classificação de e-mails**. Disponível em:
<<https://jreduardo.github.io/ce064-ml/work-master.pdf>>. Acesso em: 20/12/2020.

SEMICONDUCTOR, D. **DS1307/DS1308**. Disponível em:
<<https://www.alldatasheet.com/datasheet-pdf/pdf/123888/DALLAS/DS1307.html>>.
Acesso em: 06/04/2020.

SEMTECH. **SX1276/77/78/79 - 137 MHz to 1020 MHz Low Power Long Range Transceiver**. Disponível em:
<<https://www.semtech.com/products/wireless-rf/lora-transceivers/sx1276>>. Acesso em:
06/04/2020.

SHAEFFER, D. K. MEMS inertial sensors: a tutorial overview. **IEEE Communications Magazine**, [S.l.], v. 51, n. 4, p. 100–109, 2013.

SHIN, J. *et al.* Sensitive wearable temperature sensor with seamless monolithic integration. **Advanced Materials**, [S.l.], v. 32, n. 2, p. 1905527, 2020.

SMITH, K. *et al.* An integrated cattle health monitoring system. *In: INTERNATIONAL CONFERENCE OF THE IEEE ENGINEERING IN MEDICINE AND BIOLOGY SOCIETY*, 2006., 2006. **Proceedings [...]** [S.l.: s.n.], 2006. p. 4659–4662.

SOENDERGAARD, N. *et al.* **Impactos da covid-19 no agronegócio e o papel do Brasil**. [S.l.]: Insper-Centro do Agronegócio Global. Texto para discussão, 2020.

TORRES, G. G. **Tecnologia assistiva para detecção de quedas. Desenvolvimento de sensor vestível integrado ao sistema de casa inteligente**. 2018. 71 p. Dissertação (Mestrado) — Programa de Pós Graduação em Engenharia Elétrica, Universidade Federal do Rio Grande do Sul (UFRGS), Porto Alegre, 2018.

WOUTERS, P. *et al.* A low power multi-sensor interface for injectable microprocessor-based animal monitoring system. *In: SENSORS AND ACTUATORS A: PHYSICAL*, 1994. **Proceedings [...]** Elsevier, 1994. v. 41, n. 1-3, p. 198–206.